

SBCAS2023 | 27 A 30 DE JUNHO DE 2023

XXIII Simpósio Brasileiro de
Computação Aplicada à Saúde



LIVRO DE MINICURSOS

Realização



SBCAS2023

Patrocínio



Apoio



Organização





Organizadora:

Natalia Castro Fernandes (UFF)

Livro de Minicursos do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2023)

Sociedade Brasileira de Computação
Porto Alegre
2023

Dados Internacionais de Catalogação na Publicação (CIP)

S612 Simpósio Brasileiro de Computação Aplicada à Saúde (23. : 27 – 30 junho 2023 : São Paulo)
Minicursos do SBCAS 2023 [recurso eletrônico] / organização: Natalia Castro Fernandes. Dados eletrônicos. – Porto Alegre: Sociedade Brasileira de Computação, 2023.
255 p. : il. : PDF ; 170MB

Modo de acesso: World Wide Web.

ISBN 978-85-7669-546-2 (e-book)

1. Computação – Brasil – Evento. 2. Aprendizado de máquinas. 3. Padrões de Dados de Saúde Digital. 4. Internet das Coisas. 5. Telessaúde. I. Fernandes, Natalia Castro. II. Sociedade Brasileira de Computação. III. Título.

CDU 004(063)

Ficha catalográfica elaborada por Annie Casali – CRB-10/2339

Biblioteca Digital da SBC – SBC OpenLib

Índices para catálogo sistemático:

1. Ciência e tecnologia dos computadores : Informática – Publicação de conferências, congressos e simpósios etc. ... 004(063)

Sociedade Brasileira de Computação – SBC

Presidência

Raimundo José de Araújo Macêdo (UFBA), Presidente

André Carlos Ponce de Leon Ferreira de Carvalho (USP), Vice-Presidente

Diretorias

Renata de Matos Galante (UFRGS), Diretora Administrativa

Carlos André Guimarães Ferraz (UFPE), Diretor de Finanças

Cristiano Maciel (UFMT), Diretor de Eventos e Comissões Especiais

Itana Maria de Souza Gimenes (UEM), Diretora de Educação

José Viterbo Filho (UFF), Diretor de Publicações

Tanara Lauschner (UFAM), Diretora de Planejamento e Programas Especiais

Marcelo Duduchi Feitosa (CEETEPS), Diretor de Secretarias Regionais

Alírio Santos de Sá (UFBA), Diretor de Divulgação e Marketing

Jair Cavalcanti Leite (UFRN), Diretor de Relações Profissionais

Carlos Eduardo Ferreira (USP), Diretor de Competições Científicas

Wagner Meira (UFMG), Diretor de Cooperação com Sociedades Científicas

Michelle Silva Wingham (UNIVALI), Diretora de Articulação com Empresas

Diretorias Extraordinárias

Leila Ribeiro (UFRGS), Diretora de Ensino de Computação na Educação Básica

Contato

Av. Bento Gonçalves, 9500

Setor 4 - Prédio 43.412 - Sala 219

Bairro Agronomia

91.509-900 – Porto Alegre RS

CNPJ: 29.532.264/0001-78

<http://www.sbrc.org.br>

Mensagem da Coordenação Geral do SBCAS 2023

A Transformação digital na saúde até 2019 avançava e estava se tornando-se cada vez mais relevante para a sociedade. Porém, com a pandemia da COVID-19, o avanço rápido da saúde digital se tornou não só necessário como inevitável. Neste momento, todas as áreas da ciência, principalmente a computação se viu na obrigação de auxiliar neste avanço. O resultado disto é apresentado nestes minicursos que foram oferecidos no SBCAS 2023. A inteligência artificial foi e vem sendo a grande área da computação que tem mais auxiliado nesta mudança tecnológica na saúde e tivemos, portanto, dois minicursos que abordaram o tema. A evolução da doença ao longo do tempo é um dos fatores mais importantes na saúde e precisa ser considerado em qualquer estudo de diagnóstico e tratamento de pacientes, e esse tema é abordado no minicurso “Aprendizado de Máquina Supervisionado para Séries Temporais na Área da Saúde”. Por outro lado, entender como a máquina chegou a uma conclusão a respeito de uma doença é crucial para o profissional de saúde, pois desta forma, além do aprendizado a respeito da doença é possível traçar caminhos para a avaliação e tratamento, mesmo que estes pontos sejam auxiliados por outra máquina inteligente. Neste ponto, o minicurso “Explicando as decisões com IAs: Demonstrando sua aplicação em imagens médicas” nos mostra como podemos ter explicações nas decisões em Inteligência Artificial. Mas nada disso seria possível se não tivésemos os dados coletados e devidamente processados para o uso tanto da inteligência artificial quanto para análises complexas, portanto, um minicurso demonstrando a importância e como preparar os dados para a área da saúde não poderia deixar de ser ministrado: “Padrões e Soluções para Armazenamento, Compartilhamento e Estruturação de Dados em Saúde Digital: Privacidade, Integração e Desafios” foi o minicurso que abordou estes temas para trazer segurança ao paciente (não só dos dados, mas no uso destes dados). Finalmente, como se beneficiar de tudo isso? Com o propósito de apresentar como usar e os avanços que a computação vem trazendo para a área da saúde, dois minicursos neste contexto estiveram presentes no SBCAS 2023, uma delas sobre o Internet das Coisas, “Internet das Coisas e ambientes inteligentes no contexto da Saúde”, e a outra que foi a menina dos olhos do mundo todo na COVID-19 e que veio para ficar principalmente no Brasil, a telessaúde, “Nova Geração da Telessaúde: Oportunidades, Tendências e Desafios”. Para consolidar estes assuntos, o livro de minicursos vem acrescentar e tornar possível àqueles que não puderam estar conosco no SBCAS 2023 desfrutarem destes assuntos tão fascinantes e importantes para a era atual da saúde digital no mundo e no Brasil.

Márcia Ito, M.D., PhD.

Coordenadora Geral

XXIII Simpósio Brasileiro de Computação Aplicada à Saúde

Comissão Especial de Computação Aplicada à Saúde

Sociedade Brasileira de Computação

Mensagem da Coordenação de Minicursos do SBCAS 2023

O Livro de Minicursos do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2023) traz os textos dos minicursos selecionados e apresentados nesta edição do evento, incluindo cinco minicursos selecionados. As questões abordadas são de grande relevância para a computação aplicada à saúde, tanto no contexto nacional, quanto no internacional, considerando temas como o aprendizado de máquinas, os padrões de dados em saúde, a aplicação de Internet das Coisas e novas aplicações de telessaúde. Dentro desse contexto, os minicursos trazem uma oportunidade de aprendizado e atualização de conhecimentos para comunidade, inspirando novos trabalhos e áreas de pesquisa em níveis de graduação e pós-graduação.

Os minicursos foram selecionados através de um processo de revisão por pares, contando com pesquisadores de grande renome na área em seu comitê de programa, que realizaram uma criteriosa seleção. Agradeço a todos os membros do comitê por suas valiosas contribuições para os trabalhos e dedicação no processo de revisão. Da mesma forma, agradeço à coordenação geral do SBCAS 2023, realizada pela Profa. Márcia Ito, por todo o seu apoio e suporte à realização dos minicursos. Agradeço também aos autores, pelos textos produzidos e pelas apresentações no Simpósio.

Finalmente, desejo que todos os leitores aproveitem o conteúdo desse livro, preparado com muito zelo e qualidade técnica pelos autores dos minicursos.

Natalia Castro Fernandes, D.Sc. (UFF)
Coordenadora da Trilha de Minicursos
XXIII Simpósio Brasileiro de Computação Aplicada à Saúde

Comitê de Programa de Minicursos

Alessandra Macedo, USP

Andrey Pimentel, UFPR

Debora Muchaluat-Saade, UFF

Flavio Seixas, UFF

Lucas Ferrari de Oliveira, UFPA

Luciana Salgado, UFF

Marcia Ito, PPG-GTSP - CEETEPS

Marcos Barreto, London School of Economics and Political Science

Natalia Castro Fernandes, UFF

Paulo Ambrósio, UESC

Robespierre Pita, UFBA

Comissão Especial De Computação Aplicada À Saúde (CE-CAS) - SBC

Paulo Eduardo Ambrósio, UESC - Coordenador

Cristiano André da Costa, UNISINOS - Vice-coordenador

Débora Christina Muchaluat Saade, UFF

José Raphael Bokehi, UFF

Lucas Ferrari de Oliveira, UFPR

Marcia Ito, Fatec-SP

Rodrigo de Melo Souza Veras, UFPI

Sérgio Teixeira de Carvalho, UFG

Sumário

Mensagem da Coordenação Geral	iv
Mensagem da Coordenação de Minicursos	v
Comitês	vi
Capítulo 1: Internet das Coisas e Ambientes Inteligentes no Contexto da Saúde	
Analúcia Schiaffino Morales, Sílvio César Cazella	1
Capítulo 2: Aprendizado de Máquina Supervisionado para Séries Temporais na Área da Saúde	
Diego F. Silva, Guilherme G. Arcencio, José Gilberto B. M. Júnior, Vinícius M. A. de Souza, Yuri G. A. da Silva	51
Capítulo 3: Explicando as decisões com IAs: Demonstrando sua aplicação em imagens médicas	
Elineide Silva dos Santos, Justino Duarte Santos, Luis Henrique Silva Vogado, Leonardo Pereira de Sousa, Hécio de Abreu Soares and Rodrigo de Melo Souza Veras	92
Capítulo 4: Padrões e Soluções para Armazenamento, Compartilhamento e Estruturação de Dados em Saúde Digital: Privacidade, Integração e Desafios	
Nicollas R. de Oliveira, Yago de R. dos Santos, Ana Carolina R. Mendes, Guilherme N. N. Barbosa, Marcela T. de Oliveira, Rafael Valle, Dianne S. V. Medeiros e Diogo M. F. Mattos ...	134
Capítulo 5: Nova Geração da Telessaúde: Oportunidades, Tendências e Desafios	
Gabriel C. de Almeida, Allan C. N. dos Santos, Celine L. de A. Soares, Paula Caroline A. Pinto, Felipe da S. Dal Bello, Yolanda Eliza M. Boechat, Flávio Luiz Seixas, Alair Augusto S. M. D. dos Santos, Claudio T. Mesquita, Evandro T. Mesquita, Débora C. Muchaluat-Saade e Natalia C. Fernandes	187

Capítulo

1

Internet das Coisas e Ambientes Inteligentes no contexto da Saúde

Analúcia Schiaffino Morales¹, Sílvio César Cazella²

Abstract

The Internet of Things and Intelligent Systems have stood out in the context of Healthcare. The solutions developed in this context have covered patient care and health professionals, seeking to allow monitoring through the use of non-invasive devices and other applications that benefit health care. This chapter presents considerations about the Internet of Things and Intelligent Environments, including a brief theoretical background highlighting the International Telecommunication Union - Telecommunication standards for this area, applications that have been developed in recent years including both the Internet of Things and the use of Artificial Intelligence, following with reflections on the main challenges and barriers associated with the health care area. A review of the research developed in the area and reported in relevant publications in recent years is presented. At the end of the chapter, the Brazilian and European Community efforts to regulate the use of Artificial Intelligence to mitigate the risks of impact on society and citizens are presented.

Resumo

A Internet das Coisas e os Sistemas Inteligentes têm se destacado no contexto da Saúde. As soluções desenvolvidas neste contexto têm abrangido o cuidado ao paciente e o profissional da saúde, buscando permitir o monitoramento através do uso de dispositivos não invasivos e outras aplicações que beneficiam o atendimento em saúde. O presente capítulo apresenta considerações a respeito de Internet das Coisas e Ambientes Inteligentes, incluindo uma breve fundamentação teórica destacando as normas do International Telecommunication Union - Telecommunication para esta área, aplicações que têm sido desenvolvidas nos últimos anos incluindo tanto a Internet das Coisas quanto o uso de Inteligência Artificial, seguindo com reflexão dos principais desafios e barreiras associados à área de cuidados da saúde. É apresentada uma análise das pesquisas desenvolvidas na área e que se encontram reportadas em publicações relevantes dos últimos anos. No final do capítulo são apresentados os esforços Brasileiro e da Comunidade Européia em regulamentar o uso da Inteligência Artificial para mitigar os riscos de impacto na sociedade e no cidadão.

¹Professora da Universidade Federal de Santa Catarina, analucia.morales@ufsc.br, <http://lattes.cnpq.br/1734491043363752>

²Professor da Universidade Federal de Ciências da Saúde de Porto Alegre, silvioc@ufcspa.edu.br, <http://lattes.cnpq.br/9173977294178020>

1.1. Introdução

Em 2022 o site do Unfoldabs³ apresentou uma compilação, em um infográfico, sobre tecnologias que se encontravam em destaque quanto a investimentos naquele ano. Nesta compilação foi destacada a Internet das coisas (do inglês, *Internet of Things-IoT*), com uma previsão de investimento de 1,39 trilhões de dólares até 2026 , uma previsão de investimento de 726 bilhões de dólares até 2028 em Assistência Médica focada em Medicina Personalizada e previsão de investimento de 0,4 trilhões de dólares até 2024 em Inteligência Artificial (IA). Estes valores robustos em investimentos mundiais acabaram por incentivar de forma efetiva o desenvolvimento de uma série de soluções baseadas nestas tecnologias, o que pode ser evidenciado na publicação da *Food and Drug Administration* (FDA) dos Estados Unidos, com a listagem de dispositivos médicos habilitados para inteligência artificial e aprendizado de máquina⁴ , lista que teve acréscimo de 178 dispositivos no final do ano de 2022, totalizando 522 dispositivos habilitados pelo órgão.

No Brasil, o relatório técnico de 2022, redigido pelo Comitê Técnico de Prospecção de Saúde Digital (CT-SD) da Rede Nacional de Pesquisa (RNP)⁵, denominado “Relatório Técnico: Visão do Futuro da Saúde Digital”, destaca a relevância e potencial da Inteligência Artificial aplicada a Saúde, sendo importante observar questões relacionadas à ética, usabilidade, adequação e aplicabilidade, identificando relações com a educação em saúde, o que recai na conhecida educação permanente do profissional da saúde e aspectos relacionados à segurança cibernética e pesquisa. O relatório destaca a importância de observar o alinhamento entre a Inteligência Artificial e a Internet das coisas , Internet Médica das Coisas (do inglês, *Internet of Medical Things- IoMT*), dados do mundo real na saúde (do inglês, *Real World Data*) e evidências do mundo real (do inglês, *Real World Evidences*) (RNP, 2023). Segundo o relatório, uma linha de pesquisa relevante para a Saúde Digital se refere a tecnologias móveis e apresenta como solução a ser explorada de forma ampla e no curto prazo a “Internet das Coisas aplicada a Serviços de Saúde”. Outras soluções nesta mesma linha são destacadas, como o auxílio ao diagnóstico e seguimento de agravos em saúde; monitoramento remoto de pacientes, melhora na adesão ao tratamento de doenças crônicas; captura de dados de desfechos reportados pelos pacientes e soluções acopladas a plataformas de diagnóstico POC (*Point Of Care*) entre outras. Outra linha de pesquisa foca na importância dos biossensores móveis, os vestíveis e "ingeríveis", destacando os dispositivos como sensores fisiológicos para coleta contínua de dados elétricos, ópticos, sonoros e cinéticos para monitoramento de parâmetros clínicos e o uso de biossensores móveis para melhoria de processos de

³ A UnfoldLabs é uma provedora de tecnologia e soluções referentes a experiência do Cliente com sede em San Diego, Califórnia. <https://unfoldlabs.com/infographics/top-22-technology-trends-2022.html>

⁴<https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-aiml-enabled-medical-devices>

⁵ Organização social brasileira vinculada ao Ministério da Ciência, Tecnologia e Inovação (MCTI) e mantida por esse, em conjunto com os ministérios da Educação (MEC), das Comunicações (MCom), Turismo, Saúde (MS) e Defesa (MD), que participam do Programa Interministerial RNP (PRO-RNP).

gestão em saúde, entre outros (RNP, 2023).

Cabe ressaltar os esforços nacionais e regionais que buscam promover o desenvolvimento da Inteligência Artificial aplicada à Saúde tendo linhas de pesquisa e eixos alinhados com demandas apresentadas no “Relatório Técnico: Visão do Futuro da Saúde Digital”. Destaca-se o esforço do Ministério de Ciência, Tecnologia e Inovação (MCTI) juntamente com órgãos de fomento em apoiar via editais públicos o desenvolvimento de Centros de Pesquisa, como o “Centro de Inovação em Inteligência Artificial para a Saúde”⁶, coordenado pela Universidade Federal de Minas Gerais, caracterizado como um centro de pesquisa e desenvolvimento de soluções avançadas de Inteligência Artificial, com competência para ajudar profissionais de saúde no diagnóstico e tratamento de doenças, bem como orientar gestores de saúde na programação de ações de prevenção e organização da assistência à saúde. Este centro agrega mais de cento e cinquenta pesquisadores, oriundos da Universidade Federal de Minas Gerais, Universidade Federal de Ciências da Saúde de Porto Alegre, Universidade Federal do Rio Grande do Sul, Universidade do Vale do Rio dos Sinos, Pontifícia Universidade Católica do Rio Grande do Sul, Universidade Federal de Pelotas, Universidade Federal do Amazonas, Universidade Estadual do Amazonas, Faculdade de Engenharia de Sorocaba e empresas parceira, estando organizado em quatro linhas de pesquisa: Ética e Valores Humanos, Modelos e Algoritmos, Gerenciamento e Engenharia de Dados, e Sistemas Computacionais.

Neste cenário destaca-se também o “Centro de Inteligência Artificial aplicada à Saúde”⁷ coordenado pela Universidade Federal do Rio Grande do Sul, que se constitui em uma rede aprovada no Programa de Redes Inovadoras de Tecnologias Estratégicas (RITEs) do estado do Rio Grande do Sul, tendo por objetivo desenvolver pesquisa científica de excelência e gerar tecnologia e inovação tendo como Eixo Estratégico Prioritário “Ciência de Dados e Inteligência Artificial” e como Tecnologia Estratégica Predominante “Inteligência Artificial” e “Computação em Nuvem”. Este centro agrega quarenta e quatro pesquisadores, das áreas da Ciência da Computação e da Ciências da Saúde, oriundos da Universidade Federal do Rio Grande do Sul, Universidade Federal de Ciências da Saúde de Porto Alegre, Universidade Federal de Santa Catarina, Universidade do Vale do Rio dos Sinos, Pontifícia Universidade Católica do Rio Grande do Sul, Universidade Federal de Pelotas, Universidade de Évora, Universidade Federal de Rio Grande, Universidade Federal de Santa Maria, Universidade de Passo Fundo, e pesquisadores associados ao Hospital de Clínicas de Porto Alegre (HCPA), Hospital São Lucas da PUCRS, Hospital Universitário Dr. Miguel Corrêa Jr. (da FURG) e Hospital Mãe de Deus, e às startups Noharm.ai e Epigenica Biosciences. A rede conta com a colaboração da UNIMED Porto Alegre e da empresa NVidia.

Todo este cenário atual favorável para o desenvolvimento de pesquisas em Inteligência Artificial e Internet das Coisas, já era observado em 2018 com previsão nacional que se alinham com as apresentadas em perspectiva mundial. De acordo com o

⁶ <https://ciia-saude.dcc.ufmg.br/>

⁷ <https://www.ufrgs.br/ciars/>

relatório do Ministério da Ciência e Tecnologia, foi estimado que até 2025, no mundo, a Internet das Coisas ou *Internet of Things* (IoT) apresentando um impacto econômico de cerca de US\$ 4 a 11 trilhões, valor muito maior que a robótica avançada, as tecnologias de sistemas de nuvem (*cloud computing*), e superando até mesmo a rede de internet móvel. No Brasil, de acordo com o documento, o impacto potencial atingirá cerca de US\$ 50 a 200 bilhões nos próximos anos, valor que representa aproximadamente 10% do PIB brasileiro (BNDES, 2018). Internet das Coisas é considerada chave no movimento de transformação digital da indústria e trata-se de um instrumento para o desenvolvimento sustentável da sociedade brasileira. Potencializando a competitividade econômica, fortalecendo as cadeias produtivas brasileiras e promovendo uma melhoria da qualidade de vida. Entre os eixos do estudo, a saúde foi apontada como uma das áreas estratégicas, tendo como objetivo contribuir para a ampliação do acesso à saúde de qualidade no Brasil, através de uma visão integrada dos pacientes, descentralização da atenção à saúde, e da melhoria da eficiência das unidades de saúde. Foram elencados os principais desafios para a saúde, entre eles: (1) tratamento de doenças crônicas; (2) tratamento de doenças infectocontagiosas; (3) promoção e prevenção da saúde; e (4) melhoria na eficiência de gestão. No entanto, até o momento, a Internet das Coisas não foi implantada de forma integral, existem muitos trabalhos publicados na literatura científica nacional e internacional, consistindo na sua maioria soluções ainda sem maturidade de pesquisa, apresentando trabalhos em nível de conceitos a protótipos com poucos testes efetivos de população (BNDES, 2017).

Internet das Coisas associada às técnicas de inteligência artificial para muitos autores têm sido considerado um dos mais poderosos paradigmas da atualidade, capaz de compartilhar dados de todas as coisas através do globo, usando mecanismos de comunicação avançado e aplicando recursos de inteligência artificial para melhorar as condições de serviços de saúde (Qadri et al., 2020). Entre os avanços destacam-se melhorias em processos diagnósticos, monitoração remota de pacientes e outros recursos que poderão auxiliar a enfrentar problemas futuros ligados à área de saúde. Neste contexto, será necessário compreender melhor os conceitos e estruturas computacionais necessárias para a implantação de Internet das Coisas e IA na área de atenção à saúde e seus desafios. Entre os fundamentos a serem aprofundados estão propostas de arquiteturas, plataformas, protocolos de comunicação, dificuldades relacionadas à transmissão sem fio, e uso de dispositivos sensores invasivos e não invasivos, que compõem o ecossistema de Internet das Coisas em saúde (Habibzadeh et al., 2020; Nasajpour et al., 2020; Sadoughi et al., 2020).

Os efeitos do vírus SARS-COV-2 sob a população mundial foram devastadores, demonstrando a fragilidade dos sistemas de saúde em todo o mundo. Esta situação real de enfrentamento do COVID-19 demonstrou que os sistemas de saúde não estavam preparados para uma situação totalmente imprevisível como esta. Métodos alternativos para mitigar a propagação da doença, tais como, isolamento social, medidas severas de quarentena (*lockdown*), monitoração e atendimento remoto e o rastreamento de contatos dos casos de infectados, foram algumas das medidas adotadas no mundo todo como alternativa para combater a pandemia. Outro fator preocupante que poderá gerar

sobrecarga nos sistemas de saúde será o aumento do envelhecimento da população, apontado pela Organização Mundial da Saúde (OMS) como um grande desafio a ser mitigado nos próximos anos (OMS, 2015). Estas questões ajudam a compreender o interesse em desenvolvimento tecnológico para esta área. A ampliação da saúde digital e o uso de dispositivos tecnológicos e remotos, poderá melhorar o atendimento em países em desenvolvimento, principalmente onde os recursos para a população são escassos ou quase inexistentes. Existem diversos trabalhos direcionados ao uso de tecnologia em saúde, que é apontada como alternativa para os problemas de saúde em termos de redução de custos, personalização no atendimento de pacientes e gerenciamento de recursos de gestão hospitalar.

Um outro fator importante a destacar é o crescimento da indústria de eletrônicos e sistemas de transmissão, que nos últimos anos apresentou novos sistemas que permitem a infraestrutura necessária para o desenvolvimento de Internet das Coisas nas áreas de interesse do setor público e privado. As redes de comunicação avançaram e em muitos países, o uso de redes 5G já é uma realidade, o que reduz problemas de transmissão que até poucos anos eram impossíveis de se resolver. A rede 5G permite velocidades de transmissão de dados para soluções em tempo real conectando dispositivos de Internet das Coisas, servidores e bancos de dados. Esses dispositivos poderão diminuir o tempo de internação hospitalar de pacientes, mantendo os médicos conectados com seus pacientes regularmente pós-alta hospitalar, resultando em um melhor acompanhamento destes pacientes e promovendo a redução de reincidência em internações que possuem altos custos para a saúde pública (Devi et al., 2023). Além disso, os serviços remotos poderão reduzir as visitas desnecessárias aos ambientes de saúde, como ocorre em acompanhamento de pacientes de doenças crônicas, reduzindo os custos de saúde. Beneficiando pacientes e governos que cobrem parte dos custos de saúde. De certa maneira reduzir o número de visitas físicas, permite que os profissionais de saúde ofereçam melhor qualidade de serviços aos pacientes que precisam de atenção médica imediata. A pandemia de COVID-19 provou a importância de não sobrecarregar os ambientes clínicos e hospitalares com doenças mais leves (Kakhi et al., 2022).

Recursos para monitorar o sono, rastreadores de atividades físicas, dados fisiológicos e genômicos, ferramentas para diagnóstico de doenças, sensores para identificação rápida de problemas de saúde, irão ajudar as pessoas a permanecer ativas e saudáveis por um período de tempo muito mais longo. Os cuidados com a saúde são universais em um mundo onde as barreiras físicas e geográficas não limitam os tratamentos e diagnósticos disponíveis. As pessoas estarão mais conscientes a respeito da sua saúde e bem-estar e irão buscar recursos e terapias especializadas baseadas nas suas necessidades e composição molecular/genética. Tudo isso exigirá um novo nível de análise de dados, tornando o recurso de IA capaz de personalizar as demandas de cada indivíduo, tornando o sistema de assistência inteligente e integrado aos recursos de Internet das Coisas (Shetty et al., 2023). Ressalta-se que existem questões desafiadoras para estas áreas associadas ao uso de recursos tecnológicos de saúde digital e IA associados aos cuidados de saúde. Nestes últimos anos foram publicadas muitas revisões sistemáticas sobre *machine learning* aplicado à área da saúde incluindo

questões sobre o uso destas técnicas para auxílio na tomada de decisões (Deo, 2015; Rajkomar et al., 2019; Rayan et al., 2018; Scarpato et al., 2017). Sistemas inteligentes têm sido propostos para auxiliar em diagnósticos de doenças cardiovasculares, glaucoma, tipos de câncer, entre outros (Scarpato et al., 2017). Existem artigos científicos que apresentam investigação sobre as doenças mentais e emocionais (Morales et al., 2021; Rayan et al., 2018; Tiffin & Paton, 2018). O constante acompanhamento de pacientes com doenças crônicas, é uma outra forma alinhar a “IoT em atenção à saúde” e recursos e técnicas de aprendizado de máquinas que permitem uma personalização ao atendimento dos pacientes (Qadri et al., 2020; Rayan et al., 2018). Neste caso, existe ainda a preocupação em fornecer ferramentas adequadas para auxiliar na tomada de decisões médicas e no acompanhamento de atividades e monitorações constantes dos pacientes (Morales et al., 2021).

O presente capítulo apresenta considerações a respeito de IoT e ambientes inteligentes, incluindo os desafios associados à área de cuidados da saúde. Soma-se o que tem sido proposto recentemente na literatura científica, associado aos três anos de investigação por parte dos autores deste capítulo com artigos publicados envolvendo o tema, capítulos nacionais e internacionais já publicados, e através da disciplina denominada “Tópicos Especiais: Internet das Coisas e Ambientes Inteligentes no contexto da Saúde”, ministrada pelos autores no Programa de Pós-graduação em Tecnologia da Informação e Gestão em Saúde (PPG-TIGSaúde⁸) da Universidade Federal em Ciências da Saúde de Porto Alegre.

Este capítulo encontra-se organizado em cinco seções, incluindo a Introdução e Conclusão. Na seção 2 é apresentada a fundamentação teórica com embasamento dos conteúdos fundamentais deste capítulo, a Internet das Coisas em Saúde e Sistemas Inteligentes. A seção 3 apresenta aplicações e perspectivas no âmbito de sistemas inteligentes e Internet das Coisas. Algumas questões relativas aos desafios pontuais para o desenvolvimento e implantação de Sistemas Inteligentes e Internet das Coisas em saúde são discutidas na seção 4.

1.2. Fundamentação Teórica Internet das Coisas e Sistemas Inteligentes

1.2.1. Internet das Coisas para saúde

Diferentes versões têm sido associadas ao tema Internet das Coisas em saúde, na literatura são encontrados diferentes termos, como: *medicine 4.0*, *health 2.0*, *e-Health*, *Internet of Medical Things*, ou ainda *IoT framework for healthcare* (IoTHeF). Além disso, uma série de novas definições vêm sendo relacionadas aos temas sobre saúde e tecnologia, principalmente saúde digital (Al-Turjman et al., 2020; Habibzadeh et al., 2020; Minh Dang et al., 2019; Muhammed et al., 2018; Qadri et al., 2020), recentemente o termo *IoT Based Green Healthcare System* foi mencionado para se referenciar a uma plataforma que prevê a redução de gasto de energia com sensores

⁸ <https://www.ufcspa.edu.br/vida-academica/pos-graduacao/mestrado-e-doutorado/tecnologias-da-informacao-e-gestao-em-saude>

(Islam & Bhuiyan, 2023). Embora seja muito difícil produzir uma taxonomia formal e precisa com tantos novos termos que têm surgido, alguns autores se arriscam em definições sobre o tema (Aceto et al., 2018). No presente capítulo, será adotado como nomenclatura Internet das Coisas em Saúde, que corresponderia em inglês ao termo *Healthcare Internet of Things (HIoT)*. Trata-se do ecossistema composto por diversos sensores, recursos de comunicação incluindo protocolos e dispositivos, *gateways* e servidores em nuvem para a infraestrutura e armazenamento, e o que mais for necessário para coletar dados, processá-los, analisá-los, tomar decisões e vincular as ações relacionadas à comunidade de saúde envolvida, sejam pacientes, médicos ou profissionais de saúde. O espaço para a implantação pode ser um hospital, uma unidade de saúde, uma clínica, uma residência, ou até mesmo, todo este contexto inserido em um universo maior denominado cidade inteligente, onde todas as áreas e coisas estão interligadas. Neste caso, poderão ainda ser incluídos diferentes recursos para atendimento de emergências tais como controle de tráfego urbano (Al-Turjman et al., 2020).

Tabela 1– Vantagens e Desvantagens de Internet das Coisas em Saúde

Vantagens	Desvantagens
Monitoramento em tempo real dos sinais vitais dos pacientes, permitindo um acompanhamento mais efetivo e ágil.	Preocupações com privacidade e segurança dos dados pessoais dos pacientes.
Diagnósticos mais precisos melhorando a tomada de decisão devido o acesso aos dados de forma constante e precisa.	Custo elevado dos dispositivos de Internet das Coisas e de sua implementação no sistema de saúde.
Melhoria da eficiência dos cuidados de saúde, concentração centrada nos pacientes e acompanhamento das informações.	Possíveis problemas técnicos e de manutenção dos dispositivos de Internet das Coisas devido a comunicação sem fio e uso de dispositivos com baterias.
Redução de erros médicos e aumento da segurança do paciente.	Potenciais limitações do alcance da tecnologia, como é o caso da cobertura de telefonia móvel 5G.
Melhora da comunicação entre médicos e pacientes, permitindo acesso fácil e constante às informações de saúde.	Possível dificuldade em integrar a tecnologia com o sistema de saúde já existente.

Existem camadas neste ecossistema projetadas para atender as necessidades computacionais de um problema extremamente complexo, que envolve um enorme volume de dados multimodais, problemas de transmissão e necessidade de redução de latência (atrasos) para dados em tempo real, privacidade de informações de pacientes, integração e interoperabilidade de todo este ecossistema. Na Tabela 1 são apresentados algumas vantagens e desvantagens identificados em pesquisas conduzidas nos últimos anos sobre Internet das Coisas aplicada à saúde.

1.2.2. Infraestrutura de Internet das Coisas

A infraestrutura para Internet das Coisas tem sido recomendada pela *International Telecommunications Union* (ITU), através do documento Y.2060 – *Overview of the Internet of Things*, publicada em 2012, posteriormente renomeada sem alterações em 2016 para *International Telecommunication Union - Telecommunication* (ITU-T) Y.4000 (ITU, 2012). Neste documento um dispositivo para Internet das Coisas é considerado:

"Um dispositivo é um equipamento com capacidades obrigatórias de comunicação e capacidades opcionais de detecção, atuação, captura de dados, armazenamento de dados e processamento de dados. Os dispositivos coletam vários tipos de informações e as fornecem às redes de informação e comunicação para posterior processamento. Alguns dispositivos também executam operações com base nas informações recebidas das redes de informação e comunicação".

Do ponto de vista da Internet das Coisas ou IoT, um dispositivo pode ser qualquer coisa que possua recursos de comunicação. A heterogeneidade presente nos dispositivos IoT é uma das características que tornam o desenvolvimento de soluções IoT bastante complexas. Segundo este mesmo documento, apresenta a seguinte definição:

"A Internet das coisas (IoT) pode ser percebida como uma visão de longo alcance com implicações tecnológicas e sociais. Do ponto de vista da padronização técnica, a IoT pode ser vista como uma infraestrutura global para a sociedade da informação, permitindo serviços avançados interconectando coisas (físicas e virtuais) com base em tecnologias de informação e comunicação (TIC) interoperáveis existentes e em evolução. Através da exploração de capacidades de identificação, captura de dados, processamento e comunicação, a IoT faz pleno uso de "coisas" para oferecer serviços a todos os tipos de aplicativos, garantindo que os requisitos de segurança e privacidade sejam atendidos".

O documento ainda define coisas como objetos pertencentes ao mundo físico, ou ao mundo ciberfísico, sendo denominada de mundo da informação. Estas coisas podem ser identificadas e integradas através de redes de comunicação. As coisas possuem informações associadas, e podem ser estáticas ou dinâmicas. As coisas físicas existem no mundo físico e são capazes de serem sentidas, acionadas e conectadas. Exemplos de coisas físicas apresentadas pelas recomendações ITU-T incluem: o ambiente ao redor, robôs industriais, bens e equipamentos elétricos. As coisas virtuais existem no mundo da informação e podem ser armazenadas, processadas e acessadas. Exemplos de coisas virtuais apresentadas incluem conteúdo multimídia e software aplicativo. Adicionalmente, foram criados uma série de documentos ITU-T para recomendar os requisitos de aplicações e capacidades envolvendo a infraestrutura para ecossistemas de IoT, principalmente relacionado às cidades inteligentes. Ressalta-se que estes documentos estão escritos em língua inglesa no Portal da ITU⁹ (Tabela 2).

⁹ <https://www.itu.int/en/ITU-T/Pages/default.aspx>

Tabela 2 - Lista das recomendações ITU-T série Y para Internet das Coisas e Cidades Inteligentes

INTERNET OF THINGS AND SMART CITIES AND COMMUNITIES	
General	Y.4000-Y.4049
Definitions and terminologies	Y.4050-Y.4099
Requirements and use cases	Y.4100-Y.4249
Infrastructure, connectivity and networks	Y.4250-Y.4399
Frameworks, architectures and protocols	Y.4400-Y.4549
Services, applications, computation and data processing	Y.4550-Y.4699
Management, control and performance	Y.4700-Y.4799
Identification and security	Y.4800-Y.4899
Evaluation and assessment	Y.4900-Y.4999

O modelo de referência introduzido em 2012, apresenta uma estrutura genérica com quatro camadas: camada de aplicação, camada de suporte à aplicação e serviço, camada de rede e camada de dispositivos. A distribuição destas funções, apesar de ser definida em 2012, não foram especificadas com maior profundidade em documentos posteriores. Foram identificados requisitos funcionais para o desenvolvimento dos sistemas IoT, categorizados como (ITU, 2014):

- Requisitos de suporte de aplicativos;
- Requisitos de serviço;
- Requisitos de comunicação;
- Requisitos do dispositivo;
- Requisitos de gerenciamento de dados;
- Requisitos de segurança e proteção de privacidade.

Bem como, requisitos não funcionais elencados como: interoperabilidade, escalabilidade, confiabilidade, alta disponibilidade, adaptabilidade e gerenciabilidade (ITU, 2014). Entre a série de documentos citados, o modelo de referência de arquiteturas para dispositivos apresentado, utiliza uma classificação de dispositivos para aplicações IoT, com base em suas capacidades de processamento e conectividade; empregando entidades funcionais e interação dessas entidades funcionais para um modelo de referência de arquitetura para cada uma destas condições. Portanto, foram apresentadas três referências de arquiteturas para os dispositivos (ITU, 2019).

- Dispositivo *high processing and high connectivity* (HPHC): Um dispositivo IoT que não apenas possui alta capacidade de conectividade, permitindo que ele se

conecte diretamente a aplicativos e serviços em nuvem, mas também possui capacidade de processamento alta o suficiente para tomar decisões e executar algoritmos complexos (por exemplo, inteligência artificial (IA) algoritmos relacionados). Os dispositivos possuem características autônomas, tomando decisões sobre suas próprias funções e também coordenando outros dispositivos dentro do ecossistema.

- Dispositivo *low processing and high connectivity* (LPHC): Um dispositivo IoT que atua apenas como uma interface para coleta de dados de coisas físicas ou do ambiente que ele pertence e/ou realiza operações em coisas físicas ou deste ambiente. O dispositivo apresenta recursos de conectividade suficientes para se conectar diretamente às redes de comunicação.
- Dispositivo *low processing and low connectivity* (LPLC): Um dispositivo IoT que atua apenas como uma interface para coleta de dados de coisas físicas ou do ambiente e/ou executa operações em coisas físicas ou do ambiente. Este dispositivo não possui recursos de processamento suficientes para tomar decisões ou executar algoritmos complexos; ele também não possui recursos de conectividade suficientes para se conectar diretamente às redes de comunicação.

Apesar de todo esforço que vem sendo empregado e resumido até aqui, o tema apresenta alta complexidade, dificultando que um único padrão permita o desenvolvimento de dispositivos de Internet das Coisas e suas aplicações. Além disso, nos últimos anos têm surgido novos protocolos de comunicação e novos dispositivos que integram as características definidas pelos documentos como dispositivos, sejam coisas físicas ou digitais. Com relação à área da saúde, nestes documentos não foram apresentados modelos de referência específicos, mas as informações apresentadas até aqui auxiliam no entendimento de requisitos funcionais e não funcionais para esta área. É interessante ressaltar algumas diferenças entre a Internet das Coisas e a Internet das Coisas aplicada à saúde, destacadas em (Qadri et al., 2020) com relação à abrangência de atuação, que na Internet das Coisas engloba uma grande área geográfica servindo a um único propósito.

Quando aplicada à área da saúde tem sua área de atuação mais restrita, em uma área fechada, dentro ou ao redor do corpo humano ou em uma unidade de saúde. Com relação a alimentação e fontes de energia, para a Internet das Coisas, as fontes de energia podem incluir energia solar e eólica em casos de aplicações no meio ambiente, e em casos de nós estacionários, os nós podem ser alimentados continuamente. Enquanto que aplicado à saúde, os nós podem coletar energia do corpo humano usando calor ou movimento, ou deixar a responsabilidade de manter o fornecimento de energia como uma preocupação para o usuário. Quando se trata de aplicações em ambientes de vida assistida, os nós podem ser alimentados continuamente por fontes de energia padrão presente nas unidades de saúde. A Internet das Coisas pode monitorar o ambiente, empregada em aplicações de defesa, monitoramento industrial ou até mesmo para identificar problemas em estradas urbanas. Enquanto que a saúde é utilizada para monitorar os sinais vitais do corpo humano ou dados relacionados ao ambiente. E para

finalizar, a integridade dos dados é mantida e existe a possibilidade de redundância para compensar os erros, dependendo do tipo de aplicação. A questão dos dados quando analisada do ponto de vista da saúde existe uma preocupação ainda maior, pois os dados devem ser preservados e transmitidos com a máxima integridade e privacidade das entidades envolvidas.

1.2.3. Arquitetura Internet das Coisas para saúde

Trata-se de um problema complexo que envolve a coleta, a distribuição, o processamento e a análise de um volume surpreendente de informações. A tecnologia permite que uma variedade de sensores possa monitorar sinais vitais, como pressão arterial, temperatura corporal, eletrocardiograma, saturação de oxigênio, e outros, facilitando a vida dos pacientes para tomarem seus medicamentos e serem supervisionados à distância, permitindo que diariamente sejam transmitidas informações aos médicos, que irão propor medicamentos e métodos de exercícios para ajudá-los a melhorar sua qualidade de vida (Islam & Bhuiyan, 2023).

Uma forma de reduzir a complexidade para solução do problema, em termos de implantação dos recursos tecnológicos necessários, utiliza-se arquitetura em camadas. É importante salientar que cada camada tem uma função específica, e no presente capítulo serão consideradas as camadas necessárias para ilustrar a infraestrutura de implantação de um IoT para saúde com base em requisitos necessários para as aplicações na área da saúde. Em (Qadri et al., 2020) são apresentadas três camadas: a primeira camada, composta pelos sensores, considerada a extremidade aberta da rede, por onde os dados são acessados. A segunda camada corresponde a camada de comunicação, através da qual os dados captados são transmitidos à terceira camada, ou camada de processamento, onde os dados são analisados. Em alguns casos, há uma quarta camada, representada pelos hospitais, ambulâncias ou redes de fornecimento de medicações. Em (Morales et al., 2021) foram identificados diversos trabalhos onde diferem o número de camadas empregadas para a implementação de IoT para a saúde. Ficando evidente a necessidade de uma camada de coisas (aquisição de dados), uma camada para comunicação e uma camada para a sincronização e processamento dos dados. Devido à alta complexidade já mencionada e o volume de informações a ser processado, tem sido incluído nas soluções uma camada intermediária entre a aquisição de sinais e o encaminhamento para a nuvem, conhecida como computação de borda ou névoa (em inglês, *fog* ou *edge computing*). No contexto da IoT em saúde são elementos muito importantes pois auxiliam a evitar perda de dados, auxiliam a reduzir o tempo de latência (atrasos), e podem ser auxiliares na construção de implementações de privacidade e segurança (Kashyap et al., 2022).

Algumas lacunas ainda estão sem soluções e são considerados desafios a serem resolvidos para a efetividade de sistemas IoT em saúde. No entanto, alguns dos problemas são minimizados pela presença de computação de borda ou névoa. Este tipo de estratégia auxilia o compartilhamento dos dados de forma eficiente e fornece uma resposta rápida aos usuários da área de saúde. Os dispositivos baseados em IoT

enfrentam inúmeros desafios, incluindo descontinuidade de dados, informações desconhecidas e grandes quantidades de transmissão de dados que poderão ser gerados pelo volume de dispositivos. Em transmissões sem fio ocorrem com muita frequência erros de bit e perda de pacotes. No setor de saúde, os dados gerados por dispositivos IoT, importantes para o diagnóstico e monitoração de pacientes poderão ser perdidos durante a transmissão. Esta camada adicional pode reduzir a quantidade de erros pois é um processamento mais próximo de onde os dados estão sendo gerados. A latência também pode ser reduzida devido a esta camada adicionada em ambientes de saúde (Abdel-Basset et al., 2019).

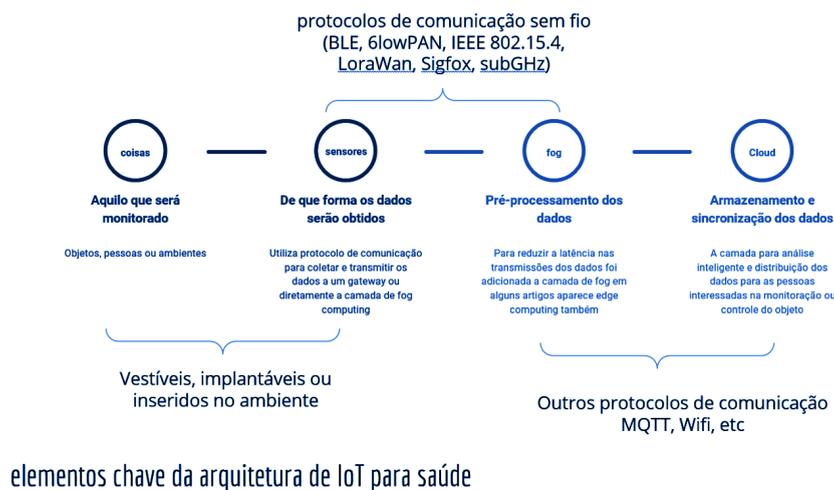


Figura 1 - Elementos para uma arquitetura de IoT para saúde
Fonte: (próprio autores)

A Figura 1 apresenta as funcionalidades mínimas para o contexto de Internet das Coisas em saúde. Um nível de coisas como recomenda o ITU, em que os dados geram sinais e estes são transmitidos através de uma camada de comunicação. Com a diversidade de dispositivos e a integração de redes corporais ou de redes de comunicação utilizadas em outros ambientes fica difícil apresentar um único tipo de dispositivo ou protocolo para esta área. Uma camada intermediária que pode realizar funções de pré-processamento, análise e segurança considerada mais próxima dos sensores, e por último uma camada de armazenamento de nuvem e sincronização dos dados. Imagine o volume massivo de dados sendo transmitidos de uma monitoração de pacientes, considerando a cada unidade de tempo dados de centenas de pacientes para apenas um link de armazenamento de uma única vez? Onde seriam armazenados tantos dados puros sem pré-processamento? Qual seria a necessidade de capacidade de armazenamento de uma nuvem para um sistema de monitoração para um único hospital? Respostas impossíveis de imaginar, pois a infraestrutura para cobrir a IoT em saúde necessita ainda garantir questões relacionadas a latência sobre o tempo de resposta dos sensores e a segurança e privacidade dos dados.

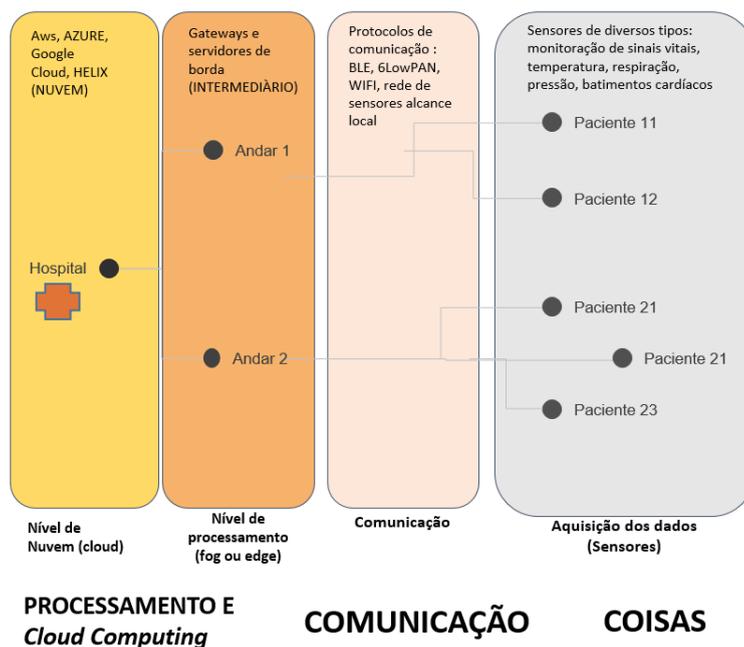


Figura 2- Exemplo de distribuição de funções em um IoT em saúde em hospital.
Fonte: (próprio autores)

A Figura 2 ilustra uma forma de atender um sistema para um hospital, distribuindo as funções por andares do hospital, em que os dados sejam coletados por sensores e os pacientes identificados por “Ids” e cada um destes conjuntos de identificadores poderiam ser agrupados por sistemas de névoa considerando os andares em que se encontram alocados estes pacientes. Desta forma, o processamento local em névoa seria categorizado para reduzir a latência e processar as informações de forma mais rápida para atender estes pacientes. A camada de comunicação não aparece, mas é a responsável por transmitir as informações de sensores para os elementos da névoa e depois para a sincronização do próprio hospital. Neste modelo pode-se reduzir a latência, melhorar o tempo de resposta, otimizar o tráfego de rede e utilização da largura de banda, melhorar a segurança dos dados e privacidade dos dados, aperfeiçoar e melhorar a qualidade de serviço relacionado ao volume de dados a serem gerados por sensores dentro de um ambiente hospitalar. Parâmetros de simulação muito semelhante foram testados através do protocolo de comunicação 6LowPAN/RPL empregando dispositivos Internet das Coisas usando nodos estacionários no simulador Contiki-OS/COOJA, mapeando diferentes cenários para confirmar questões relacionadas ao comportamento de uma rede considerando a performance diante da alta densidade de sensores em um ambiente interno hospitalar (Cieslak, 2021).

1.2.4. Camada das Coisas

Para oferecer benefícios significativos para o bem-estar dos indivíduos, melhorando a qualidade de vida e reduzindo custos com as despesas médicas. A camada

de coisas tem papel fundamental, trata-se dos elementos essenciais constituídos por coisas ou pessoas que utilizam de dispositivos sensores sem fio. Sensores ou ainda como pode ser encontrado na literatura, chamados de biossensores, podem detectar vários tipos de informações sobre a saúde corporal. Esses sensores podem ser enunciados como: vestíveis, ingeríveis ou implantáveis. Sensores vestíveis são normalmente colocados na superfície da pele para obter sinais importantes, como frequência cardíaca, frequência respiratória, saturação de oxigênio no sangue e pressão arterial. Os sensores ingeríveis geralmente estão em contato com a mucosa do corpo como por exemplo, sensor de avaliação de glicose e liberação de insulina, enquanto os sensores implantáveis geralmente estão em contato direto com tecidos humanos (Koydemir & Ozcan, 2018).

Portanto, os sensores são componentes essenciais em qualquer sistema que necessita coletar dados de grandezas físicas ou químicas, detectando indicadores fisiológicos ou marcadores patológicos, que podem auxiliar no diagnóstico, tratamento e monitoramento de doenças em longo prazo. Associando estes dispositivos e Internet das Coisas, e adicionando a inteligência artificial (IA), os sensores vêm se tornando essenciais nas investigações de tecnologias na área da saúde da nova geração (Lu et al., 2023). A aquisição de dados no contexto de IoT em saúde ainda pode ser encontrada como sensores invasivos ou minimamente invasivos, ou ainda, não invasivos. Os sensores invasivos ou minimamente invasivos são ingeríveis ou implantáveis, mas podem também ser encontrados como adesivos com micro agulhas. Destaca-se, no entanto, que a escolha dos tipos de sensores está diretamente ligada ao desenvolvimento da aplicação. Os sensores têm auxiliado em promover o diagnóstico de diferentes tipos de doenças crônicas ou mentais, monitoração de idosos, acompanhamento de doenças cardíacas, cuidados com a pele, monitoração de atividades físicas, acompanhamento de atividades diárias para pessoas com algum tipo de disfunção motora (Al-Turjman et al., 2020).

Considerando a área da saúde, os dispositivos a serem empregados poderão apresentar características associadas à potência e transmissão de sinais, tendo como características diferentes: a potência transmitida, a capacidade de transmissão, a memória, o gasto energético e uso de baterias, e o tipo de conectividade para a transmissão dos dados. De fato, existem muitos produtos no mercado que têm sido utilizados em protótipos para as coletas de dados, mas também tem sido encontrado na literatura propostas para vestíveis para coletar dados de forma não invasiva com aplicações bem específicas (Dunn et al., 2018; Seneviratne et al., 2017).

Considerando os conceitos apresentados pela ITU-T discutidos na seção anterior, pode-se afirmar que os dispositivos vestíveis encontrados nos estudos em saúde, concentram-se nos tipos LPHC e LPLC. As características dos dispositivos encontrados na literatura científica demonstram que a capacidade de processamento e transmissão muitas vezes são restritas às tecnologias de baixo alcance devido ao tamanho reduzido dos dispositivos desta área (Seneviratne et al., 2017). Ficando os dispositivos com maior capacidade de processamento e conexão (HPHC) destinados a função de gateways ou de

monitoração de ambientes de vida assistida destinados a aplicações em saúde (Marques et al., 2019).

1.2.5. Sensores não invasivos

Existe uma diversidade de sensores que vêm sendo pesquisados para uso em sistemas de IoT em saúde. Os dispositivos vestíveis podem ser categorizados como acessórios, e-têxteis ou e-adesivos. Podendo variar as tecnologias de comunicação, presença de bateria, informações sobre a duração da bateria, recursos de segurança e material de fabricação. Uma lista de 100 produtos existentes no mercado e protótipos em desenvolvimento são analisados dentro destas categorias é destacado que um dos principais desafios para os vestíveis é a segurança e integridade das informações (Seneviratne et al., 2017). Entretanto, esta é uma área que tem crescido muito com excelentes resultados considerando novos materiais para a identificação de informações relacionadas à saúde, principalmente pelos novos desdobramentos que permitem a identificação de informações biológicas em tempo real e transmissão dos dados através do avanço dos protocolos de comunicação (Dunn et al., 2018; Romanholo et al., 2021).

O acompanhamento de atividades físicas e medição de biomarcadores, tais como, a frequência cardíaca, talvez seja um dos sensores mais populares. Nos últimos anos tem intensificado a busca por sensores vestíveis que sejam não invasivos e permitam auxiliar na monitoração de pacientes. A atividade física já alguns anos utiliza recursos para auxiliar atletas amadores e profissionais com estes dispositivos e aplicativos correspondentes ao mapeamento das atividades, auxílio no registro de informações de gastos calóricos, volume de atividades desenvolvidas a cada ano, intensidade da atividade física, e mais recentemente incluindo dados de monitoração da saúde considerando o batimento cardíaco e até mesmo a pressão arterial e respiração.

Um dos sensores utilizados nos relógios de pulso ou *smartwatch*, chamados de fotoplethismografia, ou em inglês, Photoplethysmography (PPG), medem alterações no volume sanguíneo. Em muitos trabalhos o parâmetro medido é chamado de pulso do volume sanguíneo, ou em inglês, *Blood Volume Pulse* (BVP). O sensor emite uma luz no local do tecido (pulso) com um ou mais LEDs, normalmente de cor verde. O fotodiodo mede a intensidade da luz não absorvida refletida pelo tecido. A luz com comprimentos de onda mais longos penetra mais profundamente no tecido. Estes dispositivos vestíveis destinados às atividades físicas são ainda equipados com outros sensores, como por exemplo, acelerômetros e GPS, que permitem capturar a direção do movimento durante atividade física intensa e o rastreamento dos percursos percorridos pelo atleta (Castaneda et al., 2018). Na Figura 3, é apresentado o sensor PPG em um relógio utilizado para monitoramento de atividade física. No detalhe da figura, o tipo de sensor empregado para identificação dos batimentos cardíacos, sensor de fotoplethismografia ou Photoplethysmography (PPG) Sensor.

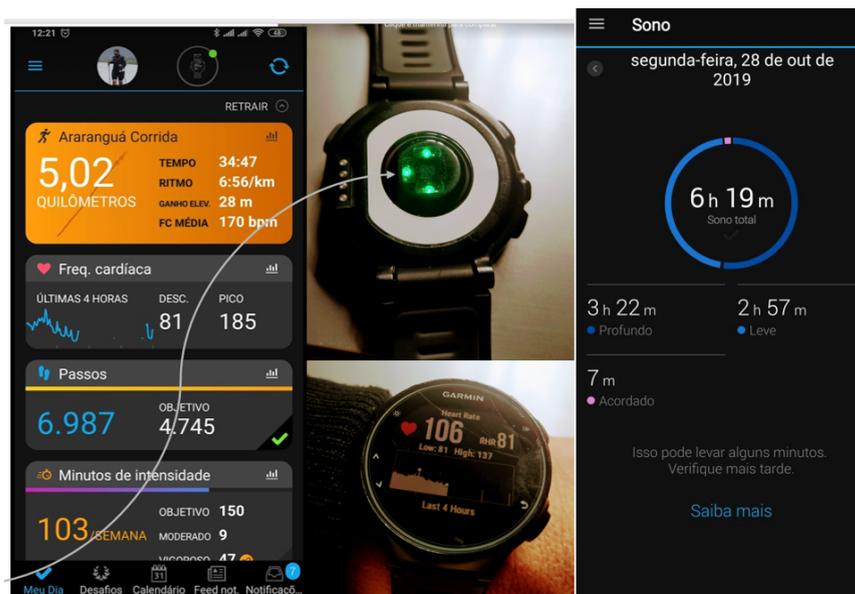


Figura 3 - Vestível para mapeamento da atividade física
Fonte: (próprio autores)

Na literatura científica, encontram-se estudos que identificam outros parâmetros coletados através de sensores não invasivos e podem ser encontrados em diferentes aplicações para saúde:

- Atividade eletrodérmica
- Frequência cardíaca e variação da frequência cardíaca
- Temperatura da pele
- Eletrocardiograma
- Eletromiograma
- Temperatura corporal
- Respiração
- Resposta galvânica da pele
- Eletroencefalograma

O potencial de sistemas de monitoramento remoto usando sensores e dispositivos vestíveis para prevenir doenças em populações em risco pode envolver ainda outros parâmetros. Como é o caso da pressão arterial, que após a pandemia de COVID-19, necessita melhorar a precisão e a exatidão das medidas para ajudar no diagnóstico precoce e na estratificação do risco cardiovascular. O desenvolvimento de sensores para monitoramento da pressão arterial em tempo real pode ter implicações significativas para a saúde digital (Al-Qatatsheh et al., 2020). Outro exemplo, é o desafio de implementar a prevenção de diabetes através de dispositivos vestíveis. As úlceras nos pés se desenvolvem devido a traumas repetitivos nos pés de pessoas com perda da sensação protetora. Este trauma recorrente resulta em uma inflamação, elevando a temperatura no local afetado como acontece com a neuropatia periférica diabética, ou

em inglês, *diabetic peripheral neuropathy* (DPN). Esta doença leva à perda de músculos intrínsecos do pé e alterações na forma do pé, promovendo áreas de alta pressão na superfície plantar dos pés durante a postura em pé ou ao caminhar.

O desenvolvimento de vestíveis para auxiliar no diagnóstico do pé diabético utilizam sensores para identificar a temperatura e a pressão da pisada através de palmilhas ou outros dispositivos acessórios (Golledge et al., 2020). Além disso, novas aplicações têm sido publicadas na literatura científica em diversas áreas e serão discutidas em uma seção mais adiante, tais como, monitoração de doenças crônicas cardiovasculares utilizando recursos de IoT (Prieto-Avalos et al., 2022; Serhani et al., 2020), IoT para o cuidado de idosos (Gralha et al., 2022), investigações sobre o uso de IoT para monitoração de doenças mentais e estresse (Morales et al., 2022).

Os artigos científicos que têm sido publicados analisam os diversos materiais empregados no projeto e fabricação de sensores vestíveis para monitoramento de fatores de risco, discutindo também alguns dos desafios técnicos da tecnologia vestível e implantável e possíveis soluções para superar essas dificuldades, como é o caso da revisão apresentada por (Koydemir & Ozcan, 2018). No entanto, não são discutidas tendências atuais do mercado bem como perspectivas futuras para estas tecnologias. Além disso, os estudos mais antigos não abordam as questões éticas e de privacidade associadas ao uso desses dispositivos. Destaca-se também que a maioria não fornece dados experimentais ou resultados sobre o desempenho desses materiais em aplicações do mundo real. Entenda-se que muitas das publicações ainda estão com um nível de maturidade a nível de protótipos ou provas de conceito, mas existem registros de produtos comercializados também. Sensores não invasivos e vestíveis tem sido coletados em vários trabalhos, seguem alguns exemplos (Koydemir & Ozcan, 2018), (Tian et al., 2019):

- Marcapasso cardíaco
- Terapia para Apneia do sono
- Controle de Doença pulmonar Obstrutiva Crônica (DOC)
- Monitoramento e regulação do nível de glicose no sangue
- Medição de Doenças Cardíacas
- Garantir a segurança de pessoas com doenças cerebrais.
- Tratamento para insuficiência renal
- Tratamento da dor crônica por doenças do sistema esquelético.
- Prevenção de queimaduras solares

1.2.6. Sensores químicos

Sensores químicos vestíveis têm surgido como alternativa para identificação de algumas doenças, como é o caso da monitorização da glicose. Apresentam como uma das principais limitações manter a estabilidade de tais dispositivos, que são frequentemente expostos a condições não controladas. Diferente dos sistemas de sensoriamento *in vitro*, baseados em condições laboratoriais controladas, é desafiador

realizar medições precisas direto no corpo. Os sensores vestíveis são expostos às mudanças de condições corporais e do ambiente, como as variações de temperatura, potencial hidrogeniônico (pH), força iônica ou umidade durante atividades internas e externas prolongadas do usuário do dispositivo. A escolha do fluido corporal (suor, fluido intersticial, etc.) a ser monitorado pelo sensor vestível é crucial, uma vez que os níveis dos biomarcadores muitas vezes precisam ser correlacionados com seus níveis sanguíneos. Metabolismos diferentes levam a diferentes proporções entre os biomarcadores presentes no fluido corporal e no sangue, o que resulta em dificuldade de se obter um fator de correlação universal para o sensor químico vestível de interesse.

No entanto, têm sido pesquisadas formas de integração de sensores químicos vestíveis e tecnologias de transmissão de informação em tempo real. A demanda contínua por várias funcionalidades em uma plataforma de sensoriamento em combinação com serviços de comunicação sem fio e análise de dados aumenta os requisitos de energia dos dispositivos. Diante deste cenário, diversas estratégias estão sendo aplicadas para enfrentar o desafio de gerenciamento de energia, como a implementação de técnicas de captação de energia, o desenvolvimento de supercapacitores e a fabricação de baterias leves e flexíveis; no entanto, o consumo de energia do dispositivo continua sendo um dos principais problemas enfrentados pelos sensores vestíveis existentes. Tem sido empregado a transmissão de imagem do resultado do sensor através do aparelho de *smartphone* por exemplo, como é feito no caso do sensor de glicose. O aparelho funciona para transmitir o dado e se for atrelado a um aplicativo já faz a atualização e sincronização com a estrutura de armazenamento em nuvem (Morales et al., 2022).

1.2.7. Camada Comunicação

Um dos maiores desafios é como transmitir os dados dos sensores, sejam eles parâmetros físicos ou químicos. Considerando que o volume de dados é imenso, a transmissão sem fio sofre diversas interferências, os dados são sensíveis ao tempo e necessitam de proteção por se tratar de dados de saúde. Mesmo havendo novas tecnologias que garantam a entrega e o volume dos dados, como é o caso do 5G, não há maneira de desenvolver um sistema IoT em saúde que utilize apenas este tipo de rede. A complexidade de uma rede de Internet das Coisas, principalmente destinada à saúde, envolve mais de um protocolo de comunicação. Mesmo com a tecnologia 5G, que tem sido apontada como uma alternativa para resolver os problemas da área da saúde considerando transmissão e acesso, nem todas as regiões do país terão cobertura dessa rede de celular e seus benefícios.

Primeiramente, analisando as necessidades que o setor de saúde tem com relação a transmissão de dados, destaca-se o tempo. Existem tomadas de decisão relacionadas à saúde que são sensíveis ao tempo. Não existe ainda uma forma de prever o tempo relativo à resposta do sistema para evitar uma fatalidade. Considere uma monitoração de um paciente, e este apresenta uma condição fatal ou o sistema prevê que o paciente irá infartar por exemplo. Qual o tempo que o sistema consegue transmitir esta informação

garantindo a entrega da mensagem ao destinatário (ambulância ou médico) e mantendo a segurança deste paciente? No caso de haver falha na transmissão neste processo, quem será responsabilizado? Esta transmissão além de ter a sensibilidade do tempo, poderá sofrer dentro do ambiente hospitalar ou até mesmo em uma residência problemas de interferência, ou mesmo o bloqueio do sinal sem fio. No caso de falha, como o sistema irá identificar o problema? Lidar com a vida de pessoas e garantir a segurança de pacientes exige determinadas garantias que o sistema sem fio atualmente, não consegue dar.

Apesar da tecnologia celular desempenhar um papel importante na infraestrutura de sensoriamento, no Brasil existem ainda diferentes modos de telefonia celular distribuídos pelo vasto território brasileiro: 3G, 4G e o 5G. São capazes de fornecer a capacidade de transmissão com taxas que variam entre 14,4 kbps (para 2G) até 100 Mbps. Em locais distantes estes sistemas de transmissão garantem o acesso à Internet, no entanto, são redes que apresentam um alto consumo de energia. A tecnologia celular tradicional consome alta potência para o processo de transmissão. Novos protocolos têm sido propostos para a finalidade de IoT, como é o caso do NB-IoT, considerada uma das principais tecnologias que atende aos requisitos de IoT. Ele também pode fornecer custos ou complexidade de dispositivo ultra baixos e baixo consumo de energia do dispositivo, bem como conectividade massiva do dispositivo (Habibzadeh et al., 2018).

No Brasil, de acordo com a ANATEL, o 5G apresenta velocidades de download e upload, para atender as necessidades do usuário convencional sendo uma opção de serviço de banda larga móvel avançada, além disso poderá ser utilizado como serviço de controle de missão crítica, provendo conexão com baixíssima latência e altíssima confiabilidade, voltada para aplicações sensíveis a atrasos e erros. A própria ANATEL, apresenta como aplicação de saúde para este tipo de serviço, as cirurgias remotas. Pode também ser utilizado o serviço de Internet das Coisas Massiva, capaz de atender uma grande quantidade de dispositivos IoT, garantindo cobertura e baixo consumo de bateria. Portanto, a tecnologia 5G apresenta diversas vantagens em relação às gerações anteriores de tecnologia de comunicação móvel. No entanto, a região de cobertura brasileira é muito ampla, e torna-se um desafio garantir que esta nova tecnologia chegue aos quatro cantos brasileiros nos próximos anos. Principalmente, nas regiões afastadas dos grandes centros urbanos, onde a monitoração de pacientes por exemplo, poderia ser feita como uma ferramenta auxiliar a já consolidada telemedicina.

Recentemente, um artigo apresentou os benefícios da implementação da tecnologia 5G em dispositivos vestíveis e para a área da saúde (Devi et al., 2023). Várias aplicações que utilizam dos recursos da tecnologia 5G foram destacados abaixo:

- A tecnologia 5G consegue garantir o monitoramento remoto de pacientes com doenças infecciosas, permitindo que os profissionais de saúde rastreiem seus sintomas e forneçam intervenções oportunas de forma rápida e segura devido à distância.

- O 5G também pode ser usado para rastrear os movimentos de indivíduos que estiveram em contato com pacientes infectados, ajudando a identificar possíveis fontes de infecção e controlando a propagação da doença.
- E por fim, a tecnologia 5G pode permitir que os profissionais de saúde prestem atendimento utilizando recursos de telemedicina, oferecendo serviço aos pacientes com doenças infecciosas reduzindo o risco de transmissão e melhorando o acesso aos cuidados destes pacientes em casa. Além disso, ao fornecer informações sobre o uso da telemedicina, diagnóstico e tratamento de doenças infecciosas é possível utilizar as informações de recomendação e aperfeiçoar o atendimento pelos sistemas de telemedicina.

A adoção da tecnologia 5G pelos sistemas de saúde pode, portanto, reduzir significativamente o custo operacional de saúde em diversas localidades. Além disso, tem fortes indícios de poder auxiliar nas questões relacionadas à latência nas respostas dos sistemas de monitoramento, na massividade de dispositivos. Além do problema de transmissão da camada de comunicação, destaca-se uma complexidade muito maior relacionada à interação com as camadas superiores para o processamento e transmissão dos dados. As mudanças constantes envolvendo as redes IoT aumentam a complexidade e dificultam as ações de gerenciamento. De forma que para manter estas redes funcionais e atender a demanda das aplicações, as redes IoT precisam se adaptar em tempo de execução, levando em conta tanto os objetivos das aplicações ao interagirem com a rede, quanto às suas próprias restrições, à medida que mudanças ocorrem em seu ambiente operacional. Esta questão inclui as redes IoT voltadas para a área da saúde, que possuem características ainda mais importantes como é o caso da latência, da energia envolvendo aplicações sensíveis ao tempo (Cordeiro, 2022).

1.2.8. Bluetooth Low Energy

O Bluetooth oferece duas opções de rádio transmissão, *Bluetooth Low Energy* (BLE) e *Bluetooth Clássico*. Estes protocolos fornecem aos desenvolvedores um conjunto versátil de soluções completas e adequadas para atender às necessidades da conectividade sem fio. Recomendado para o uso em saúde, o BLE foi projetado para operação de baixa potência e suporta várias topologias de comunicação, que vão desde o ponto a ponto até a transmissão em malha, permitindo que a tecnologia suporta dispositivos em grande escala. A tecnologia também tem sido usada como serviço de localização interna de alta precisão. Segundo o grupo responsável pela tecnologia, existe uma previsão sobre o BLE que chegará a 7.6 bilhões de dispositivos até 2027¹⁰. Destaca-se que existem várias aplicações potenciais no setor de saúde, que estão sendo projetadas para uso com BLE, vão desde o monitoramento de pacientes remotos até o rastreamento de bolsas de sangue. Ressaltando, que com esta finalidade esta tecnologia de comunicação passa a ocupar o espaço de tags RFID como alternativa de rastreamento de objetos. Existe um crescente número de dispositivos que empregam o BLE como alternativa em seus protótipos, sendo impossível mapear todas as aplicações. Muitos

¹⁰ <https://www.bluetooth.com/learn-about-bluetooth/tech-overview>

sensores vestíveis que estão no mercado, aproveitam o uso de BLE para transmitir para o *smartphone*, empregando o aparelho como um gateway para enviar as informações dos dispositivos para a nuvem. É o caso de *smartwatches* e dispositivos para coleta de dados fisiológicos como o caso do Empatica E4¹¹. Recentemente, a HeartHero¹² desenvolveu um desfibrilador externo automático móvel que vem com tecnologias de comunicação NB-IoT, GPS e BLE. O dispositivo fornece aos socorristas alertas e informações de localização assim que alguém abre o aparelho e coloca os sensores no peito de outra pessoa. A funcionalidade da Internet das Coisas é acionada e envia um alerta para o pessoal de emergência e hospitais através do BLE e do NB-IoT, para que eles possam responder adequadamente à situação de emergência. O objetivo do fabricante é ingressar no mercado doméstico comercial. Destaca-se ainda, o HoloLens 2¹³ da Microsoft, dispositivo de realidade virtual que pode ser utilizado por profissionais de saúde para se conectar com especialistas remotos, acessar os dados do paciente e até consultar imagens de ressonância magnética em 3D distantes do ponto de atendimento. Em termos de comunicação, suporta Bluetooth 5 e o WiFi 802.11ac, e pode se comunicar com qualquer dispositivo que suporta estes protocolos. Estes são apenas alguns exemplos de dispositivos que estão no mercado e utilizam este protocolo para a comunicação, mas a maioria dos vestíveis incorpora o uso deste protocolo como solução de transmissão (Seneviratne et al., 2017). A versão mais recente do BLE 5.0 com potência de transmissão de ≤ 100 mW (+20 dBm) com alcance de 40m, cerca de 30m a mais que as versões anteriores operando na mesma faixa de frequência ISM 2.4GHz (Wu et al., 2020).

1.2.9.MQTT

Em 1999, o MQTT¹⁴ (*Message Queuing Telemetry Transport*) foi criado por especialistas da International Business Machine Corporation (IBM) e da Arcom (agora Eurotech). Segundo informações disponíveis na página oficial do MQTT (2019), trata-se de um protocolo de mensagens que adota o modelo de publicador e assinante (ou *publish/subscribe*) destinado a uso com sensores de baixa potência, mas também aplicável a outros cenários. Esse protocolo foi projetado para ser extremamente simples e leve, especialmente adequado para dispositivos com restrições, como baixa largura de banda, alta latência ou redes não confiáveis. Sua principal proposta é minimizar os requisitos de largura de banda tanto da rede quanto do dispositivo, tornando-o uma escolha viável para aplicações de comunicação entre máquinas (*Machine-to-Machine - M2M*). Com estas características o protocolo tem sido amplamente utilizado para enviar as informações coletadas na camada Coisas para as camadas superiores, no entanto é um recurso que exige que o dispositivo tenha um protocolo WiFi disponível.

¹¹ <https://www.empatica.com/>

¹² <https://www.rfidjournal.com/iot-ble-enable-emergency-response-to-cardiac-arrests>

¹³ <https://www.microsoft.com/pt-br/hololens>

¹⁴ <https://mqtt.org/>

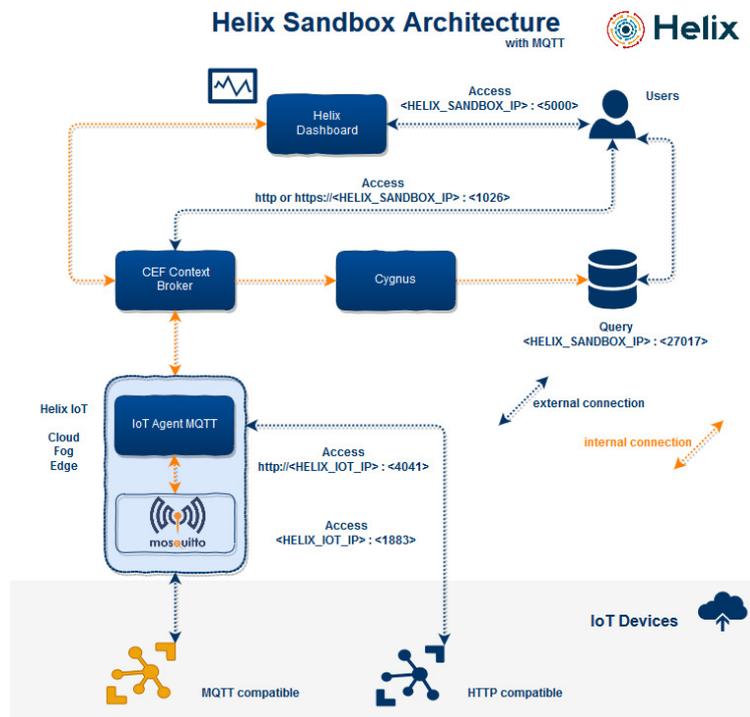


Figura 4 - Plataforma Helix SandBox

Fonte: <https://github.com/fabiocabrini/helix-iot-mqtt>

Em plataformas que operam a nível de nuvem que tem suporte para o uso com este protocolo. Uma plataforma que atende de forma simplificada e permite o uso deste protocolo é o Helix SandBox. Considerada uma plataforma aberta para prototipagem rápida de aplicativos de ambiente inteligente, o Helix SandBox visa atender a necessidade de capacidade computacional e a diversidade de padrões de transmissão para desenvolvimento de pequenos projetos de Internet das Coisas. O uso desta proposta auxilia a reduzir o custo do projeto e o tempo de desenvolvimento. Ela pode operar diretamente através do protocolo NGSI (*Next Generation Services Interface*) e com uma vasta gama de tecnologias, como por exemplo, CoAP LWM2M, MQTT, LoRaWAN, Sigfox e *Open Platform Communications* (OPC) (Cabrini et al., 2019). A Figura 4 ilustra as interações da plataforma aberta, que possui o material para o seu uso disponibilizado pelo Github do prof. Fábio Cabrini Para enviar os dados através do MQTT, utiliza-se um *broker*, que é responsável por gerenciar todas as mensagens entre os remetentes e os receptores, como por exemplo, o *broker* Mosquitto¹⁵. Este broker fará a interação entre a plataforma e os dispositivos sensores que estão sendo monitorados. O MQTT oferece uma comunicação eficiente e em tempo-real. Por exemplo, poderia ser usado para monitorar pacientes ou ambientes que tenham acesso a rede sem fio, coletando as informações de vários dispositivos e enviando aos profissionais de saúde através de um *dashboard* ou acesso pelo *smartphone*. O que facilita o monitoramento remoto de pacientes ou dos ambientes, permitindo uma resposta rápida em situações

¹⁵ <https://mosquitto.org/>

críticas, por exemplo. Além disso, o MQTT é escalável e pode lidar com grandes quantidades de dados gerados por vários pacientes e dispositivos de monitoramento simultaneamente. Para finalizar o protocolo MQTT permite configurações de mensagem para uso de criptografia e também qualidade do serviço.

1.2.10. Camada de processamento e *Cloud Computing*

Após transmitir os dados, considerando a camada “coisas” e a camada “comunicação”, existe a necessidade de armazenar os dados coletados para que estes sejam analisados posteriormente, ou então que sejam aplicados algoritmos de aprendizado de máquina ou outro recurso de IA. Os dados podem ser também encaminhados de forma bruta ao médico para auxiliar na tomada de decisões. No entanto, trata-se de Internet das Coisas aplicada à saúde, em que o volume de dados gerados apresenta demanda de processamento e armazenamento. Imagine todas as informações coletadas com uma determinada frequência, seja ela alta ou baixa, são muitos parâmetros a serem analisados por unidade de tempo. Nos últimos anos, tem surgido a alternativa de camadas de pré-processamento que realizem mais próximo dos sensores uma primeira análise, ou um processamento dos dados brutos para evitar que todo o volume de informação seja enviado para a nuvem. Destacam-se dois pontos: custo operacional e latência. Esta camada intermediária permite acrescentar recursos para uma análise inteligente dos dados, como por exemplo, um sistema com aprendizado de máquinas ou recursos de redes neurais artificiais. *Fog Computing* é capaz de fornecer serviços interativos em tempo real, dar suporte à mobilidade dos sensores e permitir a escalabilidade dentro do sistema. Além disso, está destinada a auxiliar na redução do atraso de transmissão entre os recursos (paciente e médico) para a tomada de decisões. Em alguns artigos científicos têm sido considerada ainda a presença de um *Edge Computing*, que pode ser uma máquina ou várias máquinas com capacidade de processamento e memória superior aos dispositivos sensores. Este recurso associado aos sistemas de Internet das Coisas em saúde pode ser empregado para replicar os dados para um segundo dispositivo evitando ponto único de falhas, salvaguardando as informações primárias dos sensores, este tipo de estratégia pode assegurar a entrega dos dados dentro da rede.

Enquanto que os dispositivos e nodos de *Cloud Computing* ficariam reservados para um fornecimento de dados mais analíticos, dados a longo prazo e acompanhamento do histórico do paciente. Através de recursos de cloud computing, estes dados podem chegar a vários destinatários ao mesmo tempo. Estes dados precisam ser acessados pelo médico para que se certifique da situação e realize decisões, e ao mesmo tempo, possam informar as condições do paciente para seus familiares. Obviamente, as informações disparadas ao médico seriam diferentes das informações destinadas à família, porém ambas são derivadas dos sinais fisiológicos e processamento de dados transmitidos. Pode-se criar diferentes perfis para dar destino às informações de forma a facilitar o entendimento da situação do paciente monitorado. Através da distribuição e sincronização de recursos do *Cloud Computing*, esta tarefa é perfeitamente possível. Os sistemas inteligentes precisam de um pré-processamento, posteriormente treinamento

com base em informações e casos já ocorridos para que o conhecimento contido nos exemplos possa ser transferido ao sistema inteligente. No entanto, existem questões relacionadas ao uso de informações médicas que precisam de muita atenção. Um dos aspectos mais desafiadores é a segurança e a privacidade dos dados, problemas relacionados a questões de segurança, ameaças, ataques cibernéticos, riscos e vulnerabilidades que serão discutidos na Seção 1.4.3. A interoperabilidade de sistemas e ao grande volume de dados que serão produzidos por este novo paradigma. Sensores utilizados em pacientes poderão produzir uma quantidade enorme de dados a cada segundo, em muitos casos, estes dados deverão ser processados e dar retorno imediato com acurácia e eficiência para auxiliar na tomada de decisões de médicos e outros profissionais. Portanto, existe ainda um problema de escalabilidade, as tecnologias associadas à Internet das Coisas em saúde necessitam dar suporte a diversidade de dispositivos interconectados e ao enorme volume de dados que será produzido. Para analisar diferentes tipos de dados, tais como, sinais físicos e biológicos, associados a imagens, e outros formatos de dados necessita-se de recursos tecnológicos como Big Data.

1.2.11. Ambientes Inteligentes

Ambientes inteligentes podem ser definidos como espaços físicos equipados com sensores, dispositivos e recursos computacionais para apoiar as atividades humanas e aprimorar as suas experiências. Estes ambientes podem integrar soluções baseadas em inteligência artificial e tecnologias da Internet das Coisas para automatizar diversas tarefas humanas. Uma clínica médica pode ser um exemplo de ambiente inteligente, na qual se ajusta de forma automática a iluminação, a temperatura, umidade, níveis aceitáveis de ruído e outras definições com base nas configurações. Ambientes inteligentes, através dos dados coletados, podem interagir com os Sistemas Inteligentes que são sistemas baseados em softwares que fazem uso de tecnologias relacionadas a área de inteligência artificial e da subárea de aprendizagem de máquina. Tais sistemas buscam executar tarefas que usualmente exigem a inteligência humana, como por exemplo, o reconhecimento de imagens, o reconhecimento da fala, o processamento de linguagem natural, a tomada de decisões e a previsão de desfechos. São exemplos destes sistemas os Sistemas Especialistas, Sistemas Bayesianos/Probabilísticos, Sistemas MultiAgentes, Sistemas de Recomendação, Sistemas Baseados em Casos, Sistemas Baseados em Algoritmos Genéticos, entre outros. Sistemas inteligentes são aplicados em diferentes domínios, entre estes se encontram aplicações na área da Saúde.

O fato de coletar dados e transmiti-los sem apresentar um tratamento específico não gera muito impacto ao sistema de saúde. Entregar a informação sobre o que fazer a partir dos dados analisados é muito mais promissor. Entre as principais vantagens para associar a recursos de inteligência artificial e Internet das Coisas em saúde está em se propor sistemas inteligentes para auxiliar os profissionais de saúde na difícil tarefa de tomar uma decisão. A qual deve ser feita através da combinação de experiências de casos similares, acrescentada de resultados de pesquisas recentes e associadas a um julgamento pessoal do profissional de saúde. Entre as formas de se basear uma decisão

está diretamente ligada ao número de pessoas que realizaram a decisão e acertaram, ou seja, a decisão correta foi tomada e existe um conjunto de evidências relacionadas. O sistema além de sugerir uma decisão precisa fornecer ao médico ou especialista de onde foi tomada a decisão para que ele possa acrescentar seu julgamento a respeito do que deve ser feito. Esta identificação e reunião de evidências pode ser incrementada pelo uso de inteligência artificial e Internet das Coisas em saúde (Morales et al., 2021). A credibilidade do uso dos recursos tecnológicos de Internet das Coisas em saúde depende muito da visão da comunidade médica.

O avanço das tecnologias computacionais e o uso frequente de mídias digitais, armazenando volumes de dados de diferentes tipos, tem contribuído para o aperfeiçoamento e avanços das técnicas de inteligência artificial. Recentemente, o ChatGPT (*chat generative pre-trained transformer*)¹⁶ da OpenAI e outras ferramentas que estão sendo lançadas pelas *big techs* têm aumentado a curiosidade a respeito do futuro de sistemas de inteligência artificial e suas aplicações. Fato é que desenvolver sistemas de apoio à decisão que possam apresentar recursos de linguagem natural e acessível às equipes médicas torna-se muito promissor para um futuro não muito distante. A inteligência artificial pode ser uma ferramenta de apoio à tomada de decisão médica, permitindo associar dados de pacientes e práticas clínicas associadas ao processo de diagnóstico e cuidados com o paciente (Deo, 2015). Processar o volume de informações através de aplicações de Internet das Coisas em saúde, empregar algoritmos e técnicas de aprendizado de máquinas e *deep learning* associados à linguagem natural como interface médica parece um caminho sem volta.

O aprendizado de máquinas é fundamental para processar uma significativa quantidade de dados e auxiliar na compreensão dos dados de uma determinada doença. A principal diferença em relação a abordagens tradicionais é que no aprendizado de máquina, o aprendizado se dá através de exemplos em forma de entrada e saída de dados, é viável para um modelo de aprendizado de máquina processar dados de milhares de prontuários, tarefa que dificilmente um cérebro humano conseguiria. Além disso, estas técnicas permitem acrescentar uma previsão à tomada de decisão do clínico, prevendo eventos futuros e aprendendo com padrões de trajetórias de condução de tratamentos de saúde e suas respostas nos indivíduos. Outra maneira ainda, é através de comparações de tratamentos com diferentes medicações e terapias que foram utilizadas em pacientes distintos que apresentavam condições similares (Rajkomar et al., 2019). Ainda neste contexto, o *deep learning* tem a capacidade de aprender em múltiplos níveis de abstração. É a técnica recomendada para aprender diferentes níveis de representação, como é o caso de sensores de diversos tipos de informação. Modelos com camadas sucessivas de dados para lidar com a característica multimodal presente nos sistemas de diagnóstico de doenças graves. Destacam-se pesquisas em doenças graves, tais como, doenças cardiovasculares, doenças mentais, doenças respiratórias e diversos tipos de câncer. Finalmente, estes recursos também podem ser empregados para melhorar o

¹⁶ <https://openai.com/blog/chatgpt>

processo de gestão hospitalar reduzindo erros no ambiente hospitalar e auxiliando na redução de custos relacionados à manutenção destes ambientes.

1.2.12. Sistemas de Recomendação em Saúde

Um método muito eficaz para filtrar informações de acesso à Internet, avaliando tendências de personalização e mudanças de hábitos de usuários empregados nos últimos anos, têm sido os sistemas de recomendação. Estes sistemas quando associados ao aprendizado profundo apresentam melhores resultados (Batmaz et al., 2019). Ao lidar com diferentes tipos de contexto e volume de informações, o aprendizado profundo (do inglês, *deep learning*), se torna indispensável pois é a técnica de aprendizado de máquinas mais indicada para sistemas com alto grau de complexidade (Zhang et al., 2019). Considerado um subconjunto do aprendizado de máquina tem como essência a capacidade de aprender vários níveis de representações e abstrações de dados, estes sistemas despontam como uma alternativa para a personalização de atendimento de pacientes na área de saúde. Destaca-se ainda que o número de publicações sobre métodos de recomendação baseados em aprendizado profundo tem aumentado nos últimos anos, fornecendo fortes evidências da disseminação deste tipo de técnica aplicada à pesquisa de sistemas de recomendação apresentando resultados promissores tanto na indústria quanto na academia.

Em sistemas de recomendação, o aprendizado profundo é recomendado pela sua eficiência de extrair características de usuários e associá-las a itens, gerando um conjunto de abordagens baseadas no usuário e nos itens ou informações de suas preferências. Estas abordagens podem ser adaptadas para um sistema que possa extrair os dados com as características de algumas doenças não graves e recomendar ações para o seu enfrentamento, como por exemplo, identificar níveis de estresse e recomendar ações para mitigá-lo antes de que a situação da doença se agrave (Morales et al, 2022). Neste contexto existe ainda a necessidade de atender a escalabilidade de soluções de Internet das Coisas em saúde, além de possuir uma diversidade de tipos de dados a serem analisados através de recursos de inteligência artificial.

A depressão é uma doença mental importante que atinge um grande número de pessoas na população, quando não tratada pode se tornar extremamente grave levando as pessoas ao suicídio. O uso de sistema de recomendação e aprendizado profundo para monitoração e melhora das condições psicológicas e emocionais através de soluções personalizadas para terapia de pacientes com sofrimento emocional é apresentado em (Yang et al., 2018). O volume de dados associado à alta diversidade de tipos de dados envolvidos nos sistemas de Internet das Coisas em saúde, apontam para este recurso uma série de possibilidades na área de gestão hospitalar, atendimento de profissionais de saúde e monitoração de pacientes em sistemas de saúde. Uma forma de prevenir problemas de saúde através de recomendação de tratamentos preventivos pode ser uma estratégia importante na redução de custos na área de saúde nos próximos anos.

1.3. Aplicações e Perspectivas

1.3.1. Doenças cardiovasculares

As doenças cardiovasculares são uma das principais causas de mortalidade mundial. Atividade física regular, boa nutrição, controle de peso e parar de fumar reduz os riscos destas doenças e suas consequências. Além disso, a pandemia de COVID-19 forçou o isolamento social e um declínio de cuidados com a os acometidos por esta doença, aumentando ainda mais o risco global da doença. Uma revisão apresentada ano passado apresenta diversos trabalhos científicos relacionados aos vestíveis para atuar na monitoração e controle das doenças cardiovasculares: são *smartwatches*, pulseiras, coletes, etc e são apontadas as doenças em que têm sido pesquisadas junto a estes dispositivos: arritmia, fibrilação atrial, insuficiência cardíaca congestiva, fibrilação ventricular e súbita morte cardíaca (Prieto-Avalos et al., 2022). De acordo com os autores, o uso destes dispositivos ajudam significativamente a reduzir os custos de tratamentos hospitalares. Considerando o monitoramento contínuo e ambulatorial, os vestíveis melhoram a precisão do diagnóstico, proporcionando aos pacientes soluções convenientes para o autocuidado por meio do monitoramento contínuo de variáveis biomédicas durante as rotinas diárias. Destacam que o uso de sinais de ECG é amplamente recomendado no acompanhamento de algumas cardiopatias. Envolve o registro da atividade elétrica do coração através da superfície do corpo do paciente. Então, com base na diferença de potencial elétrico entre dois pontos distantes do corpo, o ECG pode medir uma série de variáveis biomédicas para detectar doenças cardíacas, como insuficiência cardíaca e arritmias. No entanto, alertam que a tecnologia ECG não é recomendada para monitorar o risco de ataque cardíaco. Nesse caso, a eletrocardiografia convencional com eletrodos continua sendo a melhor opção. Os autores destacam ainda que o uso de Internet das Coisas e IA tornaram-se aliados importantes para o desenvolvimento de vestíveis e uso na área médica considerando as doenças cardiovasculares.



Figura 5- Dispositivo IoT em saúde desenvolvido no RS
Fonte: <https://eprohealth.com.br/#produtos>

No âmbito do Centro de Inteligência Artificial aplicada à Saúde (CIARS) do estado do Rio Grande do Sul, parte da equipe desenvolveu o MP IoT (Figura 5). Trata-se de um dispositivo vestível que busca aferir dados de medidas clínicas sem a supervisão de profissionais de saúde (especializados). O dispositivo funciona integrado a uma plataforma chamada eProHealth responsável pelo Registro Eletrônico de Saúde, promovendo melhoria nas atividades de tele saúde através de telemonitoramento. MP IoT foi desenvolvido com apoio da Fapergs¹⁷ e melhorado com apoio da Finep¹⁸. Consiste de um equipamento microcontrolado, capaz de aferir a Pressão Arterial (PA), a Temperatura Corporal (TC), a Saturação Oxigênio no Sangue (SPO2) e o Eletrocardiograma (ECG). O equipamento consegue aferir ainda a frequência cardíaca em Batimentos por Minuto (BPM) a partir da PA, do ECG e do SPO2. Atualmente, encontra-se depositado para registro de patente no INPI¹⁹ do equipamento e processo de monitoramento (BR 10 2022 006472 5 A2).

1.3.2. Desenvolvimento de dispositivos vestíveis com ESP32

Também é possível desenvolver um protótipo de dispositivo vestível usando poucos recursos. Realizando um sistema de aquisição de sinais responsável pelo processamento de sinais bioelétricos adquiridos por um circuito de condicionamento. O processamento empregou um micro controlador ESP32, constituído pela conversão do sinal analógico para digital (ADC), filtros digitais passa-baixa (150Hz), passa-alta (0.1Hz) e Notch (60Hz). Após a etapa de aquisição, o sistema de comunicação sem fio, enviava os sinais através da comunicação Wireless do ESP32 para uma aplicação Web, acessada por qualquer dispositivo remoto (*smartphones, notebooks* e outros). A interface de saída tinha como objetivo disponibilizar ao usuário ou agente externo, o gráfico cardíaco em tempo real. Este vestível foi todo desenvolvido pelo trabalho de conclusão de curso de graduação em Engenharia de Computação na Universidade Federal de Santa Catarina, publicado nos anais do Simpósio Brasileiro de Computação Aplicada à Saúde no ano de 2021 (Zanon et al., 2021), tendo sido selecionado como um dos melhores trabalhos, tendo uma versão estendida com sinais de vetocardiograma (Zanon, Romancini, Ourique, et al., 2022). Em sua primeira versão, o dispositivo não estava associado a um ambiente e armazenamento em nuvem. O protótipo foi testado e uma camada de segurança foi proposta e implementada para criptografar os dados a serem enviados para o servidor (Zanon, Romancini, Manoel, et al., 2022).

1.3.3. Monitoramento do ar

O monitoramento da qualidade do ar em ambientes externos e ambientes internos é uma aplicação essencial. Investigações no campo da qualidade do ar implicam em um envelhecimento saudável e uma promoção da qualidade de vida da população no futuro. A exposição de poluentes do ar pode ser definida como o contato entre um poluente transportado pelo ar e uma superfície do corpo humano. Portanto, esse

¹⁷ <https://fapergs.rs.gov.br/inicial>

¹⁸ <http://www.finep.gov.br/>

¹⁹ <https://www.gov.br/inpi/pt-br>

fenômeno envolve a presença de contaminantes no ar considerando a presença de um indivíduo naquele local durante certo período de tempo. A exposição à poluição do ar também afeta práticas benéficas e saudáveis, como andar de bicicleta em áreas urbanas. O mapeamento da qualidade do ar em tempo real usando tecnologias de computação móvel promove maior cobertura espacial quando comparada a estações fixas de qualidade do ar. Os autores apresentam uma solução para Internet das Coisas para a monitoração do ar, apresentando uma solução com ESP 32 e sensores de identificação de poluentes (Marques et al., 2020).

Além da monitoração da qualidade do ar externo, existe a preocupação com o controle em tempo real do ambiente interno e dos poluentes que ali se depositam ao longo do tempo. As pessoas normalmente gastam mais de 90% do tempo em ambientes fechados. Associações de maiores concentrações internas de dióxido de carbono (CO₂) com desempenho prejudicado as pessoas nas atividades laborais, aumento dos sintomas de problemas de saúde e pior qualidade do ar percebida documentados, e há também uma correlação evidente entre altos níveis de CO₂ interno e altas concentrações de outros poluentes do ar interno que são influenciados por taxas de ventilação de ar externo (Marques, Sanini et al., 2020).

1.3.4. Internet das Coisas Médicas para Diabetes Mellitus Tipo 1

A Diabetes Mellitus tipo 1 (DM1) é caracterizada pelos níveis elevados de glicemia na corrente sanguínea devido a dificuldade do organismo do paciente em utilizar a insulina. Isso exige que os pacientes estejam atentos às oscilações dos níveis de glicose no sangue todos os dias para deduzir um padrão e prever a glicemia futura e, assim, decidir a quantidade de insulina que deve ser injetada exogenamente para manter a glicemia dentro da faixa-alvo. Essa abordagem geralmente sofre de uma imprecisão relativamente alta, o que pode ser perigoso.

Com o avanço das tecnologias da Informação e Comunicação novas possibilidades de soluções surgem para acompanhamento remoto com a coleta e análise de dados do paciente, pode-se observar a Internet das Coisas Médicas, do inglês *Internet of Medical Things* (IoMT). O IoMT pode ser definido como qualquer equipamento médico interconectado via recurso de Internet das Coisas para auxiliar no monitoramento da saúde do paciente. Os dispositivos de Internet das Coisas para o setor de saúde usam sensores interfaciais automatizados e múltiplas camadas para facilitar a supervisão do setor de saúde sem intervenção humana (Rodríguez-Rodríguez, I., Rodríguez, J.V., Campo-Valera, M., 2023). A combinação de tais dispositivos médicos e a tecnologia IoMT auxilia na coleta, avaliação e transferência remota de dados por meio de monitoramento de saúde em tempo real, personalizado e vestível, em casa reduzindo as visitas desnecessárias ao hospital e os custos de saúde.

Pesquisas e soluções tecnológicas que permitam acompanhamento médico efetivo da saúde do paciente diabético são essenciais para os sistemas de saúde, cabendo ressaltar que o agravamento da Diabetes em pacientes, junto a comorbidades como

Hipertensão e Obesidade, representam um alto custo para o Sistema de Saúde (SUS). Os autores (Nilson, E.A.F. et. al. , 2018) reportaram que os custos totais de hipertensão, diabetes e obesidade no SUS alcançaram 3,45 bilhões de reais (R\$) em 2018, ou seja, mais de 890 milhões de dólares (US\$).

Na pesquisa conduzida por (Rodríguez-Rodríguez, I., Rodríguez, J.V. , Campo-Valera, M., 2023) são descritas variáveis relacionadas ao DM1 no contexto de IoMT. Algumas variáveis podem ser monitoradas de forma contínua com utilização dos biossensores, por exemplo as pulseiras ou braceletes inteligentes no contexto de IoT. A maioria dos sistemas de gerenciamento de diabetes inclui apenas estimativas de glicemia, insulina e refeições; no entanto, parece apropriado incluir outros fatores que possam afetar os níveis de glicose, desde que possam ser medidos ou estimados. Atualmente pesquisas sugerem a inclusão de fatores, tais como exercícios, frequência cardíaca, temperatura, entre outros.



Figura 6 - Variáveis relacionadas ao DM1 em um contexto de IoMT

Fonte: Adaptado de (Rodríguez-Rodríguez, I., Rodríguez, J.V. , Campo-Valera, M., 2023)

A Figura 6 sintetiza as variáveis relevantes para análise da DM1 no contexto da IoMT: 1) nível de glicose no sangue, 2) quantidade de insulina a ser injetada, 3) exercício aumenta as necessidades de glicose e insulina no sangue, sendo que exercício regular também equilibra o açúcar no sangue e diminui as necessidades de insulina, 4) refeições e alimentos consumidos afetam os níveis de glicose no sangue, 5) níveis de stress e de qualidade do sono, 6) temperatura corpórea, 7) transpiração, 8) idade, sexo, altura, peso e IMC , podendo ser usados para personalizar as soluções e 9) cronograma para auxiliar a identificar a evolução da insulina basal.

Com base nas variáveis citadas os autores em (Rodríguez-Rodríguez, I., Rodríguez, J.V. , Campo-Valera, M., 2023) apresentam um fluxo detalhado dos dados até o modelo preditivo baseado em aprendizado automático de máquina, subárea da inteligência artificial, para indicação de necessidade de insulina para o paciente monitorado. Os dados coletados com base nas variáveis apresentadas, uma vez transferidos por meio de sistemas de comunicação para um servidor na nuvem, devem permitir a extração de conhecimento que auxilie a identificar situações de risco ou refinar as doses de insulina do paciente. A Figura 7 descreve como os dados obtidos pelos sensores são transmitidos para a camada de computação, onde uma previsão de glicemia é realizada usando estratégias de aprendizado de máquina.

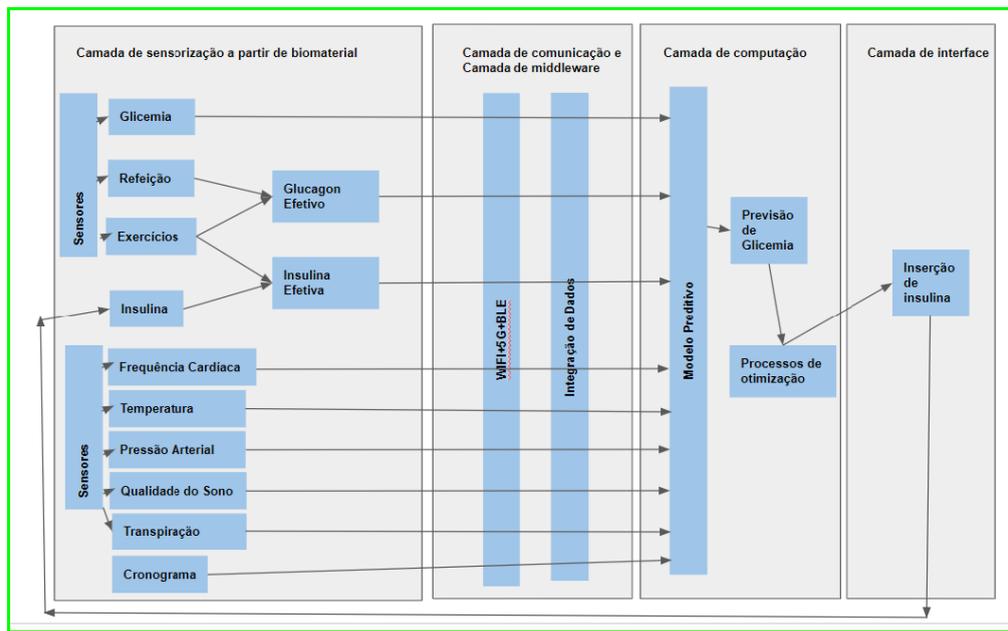


Figura 7 - Fluxo de dados para o modelo preditivo

Fonte: Adaptado de (Rodríguez-Rodríguez, I., Rodríguez, J.V. , Campo-Valera, M., 2023)

1.3.5. Projeto para identificação de stress e biomarcadores

No ano de 2020 foi aprovado o projeto intitulado de “Sistema inteligente para identificação de estresse ocupacional em equipes de saúde – sistema de vigilância de estresse e recomendações de enfrentamento” (20/2551-0000262-4) pelo Edital FAPERGS 06/2020 - Ciência e Tecnologia no Combate à COVID-19. O projeto teve como objetivo desenvolver um modelo preditivo para vigilância inteligente para o estresse ocupacional de profissionais da saúde, devido ao risco de contaminação hospitalar no período da pandemia de Covid-19.

Neste contexto, a equipe de pesquisa iniciou investigações sobre a identificação de estresse ocupacional (no projeto buscou-se pesquisar o distress) a partir de biomarcadores, avaliações de utilização de vestíveis para esta finalidade, uso de inteligência artificial para a classificação de níveis de estresse. O uso de biomarcadores

para a identificação de estresse em diferentes tipos de atividades, tais como, dirigindo, realizando atividades cognitivas ou mesmo atividades laborais diversas foram investigados.

A partir destes estudos, foram identificados os biomarcadores que apresentam maior grau de confiança para a classificação de estresse: atividades cardíacas e cerebrais, e a condutividade e temperatura da pele. Estas medidas fisiológicas estão relacionadas ao sistema nervoso autônomo, composto por dois subsistemas: o sistema nervoso simpático e o sistema nervoso parassimpático. Estes dois sistemas regulam a resposta do organismo produzindo variações fisiológicas identificadas através das alterações nos sinais fisiológicos ou biomarcadores. Dos inúmeros biomarcadores apontados na literatura, foi dada prioridade àqueles que poderiam ser utilizados para compor um dispositivo vestível de pulso para identificar o estresse ocupacional. Uma revisão sistemática para identificar vestíveis de pulso utilizados na identificação de estresse ocupacional foi então desenvolvida e publicada. Além dos biomarcadores utilizados pelos dispositivos de pulso, foram também analisados os protocolos de comunicação empregados e os algoritmos de aprendizado de máquinas utilizados nos estudos e os resultados obtidos (Morales et al., 2022):

- Variação da frequência cardíaca, com as frequências baixas e altas, apontando os níveis de estresse ou não estresse.
- Condutividade através do sensor (*Galvanic Skin Rate ou Electrodermal Activity*), presença ou ausência de estresse através da condutância na pele.
- Temperatura da pele, inversamente proporcional ao estresse.

Combinar estes parâmetros com períodos de tempo, em que estas condições se repetam em cada indivíduo seja possível ainda diferenciar de estresse agudo e crônico. E armazenar os registros individuais com histórico de cada indivíduo monitorado. Estimar a duração deste tempo também consiste em uma tarefa de pesquisa interessante. Podendo auxiliar na identificação da duração do período de estresse ocupacional e qual a sua relação com as condições psicológicas e sociais do ambiente do trabalho. Prevendo o uso de técnicas de sistemas de recomendação, porque este tipo de monitoração gera um grande volume de informações. Ou seja, este tipo de sistema necessita de recursos computacionais para processar e auxiliar na identificação do estresse e gerar, um conjunto de ações de recomendação para evitar o agravamento da situação de estresse precocemente. Entre as maiores dificuldades apontadas está a definição de uma escala aceitável para a classificação dos níveis de estresse ocupacional para os profissionais de saúde que estavam atuando na linha de frente da pandemia. Grande parte dos trabalhos lidos sobre este tema utilizam apenas a presença ou ausência de estresse. O objetivo do projeto era a identificação de alterações de biomarcadores para prevenir o agravamento do estresse ocupacional, ou seja, evitar situações de burnout devido agentes estressores presentes naquele período de pandemia (Morales et al., 2022).

Um estudo mais recente, apresentou uma revisão identificando os biomarcadores empregados para identificação de estresse e aponta sete dispositivos vestíveis comercializados para esta finalidade. Neste estudo também são destacadas as dificuldades em identificar os limiares para os níveis de estresse e apontar valores para identificar as alterações dos biomarcadores que possam auxiliar nesta definição (Chalabianloo et al., 2022). Para finalizar, a complexidade do uso de biomarcadores para a identificação de estresse ocupacional, tem como desafio empregar mecanismos adicionais para diferenciar se o estresse ocupacional é bom ou ruim. De acordo com os estudos feitos, condições de euforia e felicidade também geram alterações fisiológicas similares. Neste sentido, fica condicionado ao estudo do estado emocional para realizar a identificação se as alterações fisiológicas apontadas por sensores são de aumento ou redução de estresse, se necessitam cuidado ou não. Neste momento, estão sendo investigadas técnicas para identificar o estado emocional. Uma das possibilidades é através do uso de Teoria da Mente e multiagentes (Silva et al., 2023).

1.3.6. Envelhecimento da população

O uso da tecnologia para enfrentar os problemas de envelhecimento da população é muito promissor, em um estudo realizado recentemente (Gralha et al., 2022), os autores investigaram lacunas de pesquisa para o uso de tecnologias de IoT na área de saúde para idosos. A busca feita nas bases de dados Biblioteca Virtual em Saúde (BVS), Web of Science, Pubmed, Embase e Medline, selecionou 39 artigos de um total de 873 estudos primeiramente encontrados. Como resultados, apresentaram uma série de sensores que foram identificados nestes estudos aplicados para o cuidado da saúde de idosos. Entre as áreas que têm sido aplicadas o uso da IoT, destacaram sobre prevenção e identificação de quedas através de um sistema para auxiliar o cotidiano de idosos, destacando os desafios de ter um sistema e testar suas condições em uma situação real. Pois a maioria dos resultados são estudos a nível de protótipos. Outro registro, é a monitoração de sinais vitais através de vestíveis, entre os desafios relatam a questão do volume de dados gerados pelo sistema, tanto armazenamento quanto processamento do volume de dados gerados. Em outro trabalho a ser publicado (Morales, A. S., (in press)) foi feito um mapeamento das aplicações para o cuidado de idosos considerando ambientes de vida melhorados. Nestes ambientes, entende-se que a tecnologia pode ser associada a dar condições de vida melhores para a população idosa, desconsiderando o uso de vestíveis apenas.

Vários estudos envolvendo sensores no ambiente foram identificados e as aplicações ficaram em torno de monitoração da qualidade do ar para a identificação de presença de gases ou agentes alérgicos, ou até mesmo mofo devido às condições de vida desta população. Outros trabalhos identificados envolvem a monitoração das atividades diárias e rastreamento das pessoas idosas, questões relacionadas às quedas e configuração de situações de risco e emergências.

1.3.7. Gerenciamento de medicamentos e outras aplicações em gestão hospitalar

Outro aplicação importante, são o uso de Internet das Coisas para automatização da inclusão dos dados, minimizando ou até mesmo eliminando, os erros relacionados a administração de medicação em pacientes dentro de hospitais, permitindo uma redução de erros clínicos. De acordo com o trabalho de (Cocian et al, 2023) empregar a tecnologia para realizar a identificação automática de pacientes poderá reduzir o erro relacionado ao paciente em receber a medicação correta, evitando erros relacionados a intolerância a certas substâncias químicas ou mesmo alergias a determinados componentes. O fato é que os sistemas de informação para registro das medicações por parte das enfermeiras, acabam se tornando pontos de erros tanto no uso dos medicamentos em pacientes quanto no registro incorreto de informações. Além de se preocupar em administrar as medicações, os profissionais de saúde precisam colocar os dados no sistema empregados nos hospitais.

1.4. Desafios relacionados ao IoT em saúde

O surgimento da Internet das Coisas deve ampliar as atividades de assistência médica, melhorando a qualidade da telemedicina, que foi impulsionada pela pandemia de COVID-19. Existe uma tendência devido a transformação digital, dos sistemas convencionais migrar para sistemas com recursos de assistência mais personalizados. O uso de sensores médicos mais precisos com uma boa relação custo-benefício, sistemas com arquiteturas de Internet das Coisas padronizadas, heterogeneidade de dispositivos wearables conectados, multidimensionalidade de dados e uma alta demanda gerada que necessita da interoperabilidade são apontados como alguns obstáculos a serem vencidos nesta área. Adicionalmente, deverão ser levantadas questões sobre a privacidade e segurança das informações, pois é uma questão crucial para o futuro desta área (Zanon, Romancini, Manoel, et al., 2022). Outra preocupação relaciona-se ao desafio de desenvolver dispositivos que possam efetivamente ser utilizados pela população. Nesta seção foram elencados desafios para o desenvolvimento e implantação da Internet das Coisas em saúde e ambientes inteligentes.

1.4.1. Desafios sobre vestíveis e comunicação

A partir das informações de sensores vestíveis, invasivos ou não invasivos, observam-se algumas lacunas que ainda estão sendo objeto de pesquisa com relação aos dispositivos e seu uso na área de saúde, tais como: a) Gerenciamento de energia: dispositivos vestíveis requerem uma fonte de energia confiável que possa durar muito tempo sem a necessidade de substituição ou recarga frequente; b) Biocompatibilidade: Os dispositivos implantáveis precisam ser biocompatíveis, o que significa que não devem causar reações adversas ou respostas imunológicas no corpo; c) Segurança e privacidade de dados: dispositivos vestíveis coletam dados confidenciais de saúde, que precisam ser protegidos contra acesso não autorizado ou violações. Este ponto será aprofundado em uma seção destinada a este ponto; d) Interoperabilidade: diferentes dispositivos e sensores podem usar protocolos de comunicação diferentes, o que pode dificultar sua integração em um único sistema, e visando minimizar este problema, deve-se empregar plataformas para Internet das Coisas que permitam a integração entre

diferentes dispositivos; e) Padronização: é necessário padronizar dispositivos médicos sem fio e aplicativos móveis para garantir sua segurança, confiabilidade e interoperabilidade.

A Tabela 3 apresenta uma lista dos principais protocolos de comunicação utilizados nos dispositivos de Internet das Coisas em saúde que têm sido publicados nos últimos anos.

Tabela 3 - Principais protocolos de comunicação utilizados nos dispositivos de IoT em Saúde

Tecnologia sem fio	Desafios
Bluetooth LE	Questões relacionadas à transmissão e perdas de dados, como interferência de dispositivos externos, paredes espessas que afetam a confiabilidade dos dados. Tem sido uma boa alternativa para transmissão de dados de dispositivos que ficam próximos ao corpo dos usuários. As últimas versões do protocolo tem apresentado melhorias no que diz respeito ao número de componentes em uma rede, bem como melhorias na segurança das versões mais recentes deste protocolo.
WiFi	Também apresenta uma limitação de transmissão em ambientes internos, podendo ter interferência de outros dispositivos que usam a mesma frequência, e eventuais atrasos na transmissão de dados. Os microcontroladores para protótipos usam IEEE 802.11 g/n, que é uma versão anterior dos protocolos de WiFi que estão disponíveis nos roteadores. Por ser, uma versão anterior tem uma capacidade de transmissão menor e precisa verificar a latência de transmissão antes de empregar como solução de tomada de decisão sensível ao tempo. Para utilizar o MQTT, por exemplo, os dispositivos precisam ter acesso a uma rede WiFi, tendo que registrar a autenticação através de configuração para uso da rede.
ZigBee	Rede muito utilizada para automação residencial, sofre interferência de outros dispositivos que usam a mesma frequência, afetando a qualidade da transmissão. Possui um alcance muito baixo, necessitando integrar vários dispositivos para efetuar a transmissão em distâncias maiores. O ZigBee tem na sua camada física o IEEE 802.15.4.
5G	Rede celular com a implementação ainda em fase inicial em muitos países, incluindo no Brasil. Tem a limitação da disponibilidade e altos custos de implantação. Em termos de tecnologia é promissora devido às taxas de transferência e basicamente a falta de latência. No entanto, devido ao espaço geográfico brasileiro, existe a preocupação de contar com este tipo de tecnologia em cidades afastadas dos grandes centros.

RFID	Este tipo de rede sofre interferência de outros dispositivos eletrônicos que afetam a qualidade da transmissão. As antenas não possuem baixo alcance. Apesar de ser uma rede presente em diversos trabalhos, no período de 2014 e 2018, devido ao alcance limitado e a necessidade de uma antena coletora para os dados. É uma alternativa de rede para rastreamento de insumos, como por exemplo, de gerenciamento de medicações no contexto hospitalar.
------	---

Além disso, ainda relacionado a sensores e transmissão de dados existem também desafios relacionados ao envio do volume de dados para o armazenamento em nuvem. Armazenar dados brutos não é uma solução devido ao volume de dados e a necessidade de resposta rápida em muitas das questões relacionadas aos sensores e aplicação em saúde. Existe a necessidade de garantir a segurança do aplicativo e a segurança de pacientes que estejam monitorados por dispositivos na área de Internet das Coisas em saúde.

1.4.2. Segurança e privacidade

Sem dúvida um dos maiores desafios para a Internet das Coisas aplicada à saúde é a segurança e privacidade das informações. Considerando os cenários que envolvem vestíveis ou outros dispositivos tecnológicos; a saúde com as aplicações digitais, caminha de um modelo tradicional em direção a um modelo centrado no paciente e de saúde digital (Perwej et al., 2022). Cada camada da arquitetura de sistemas de saúde possui funcionalidades distintas como já foram discutidas, o que significa que cada nível tem diferentes requisitos de segurança e privacidade. Os dispositivos operam com transmissão dos dados sem fio, com volume exagerado de dados, com processamento e memória limitados, e muitas vezes com sensibilidade ao tempo de transmissão. Devido a limitação de recursos, faz-se necessário compreender as premissas de segurança de dados dentro destes cenários.

Além disso, no Brasil, desde 2018 existe a Lei Geral de Proteção aos Dados (LGPD) para assegurar a segurança e privacidade dos usuários no que diz respeito ao uso das informações. A adequação dos aplicativos à lei de LGPD muitas vezes força o usuário a permitir o acesso inapropriado de aplicativos ao seu *smartphone*. Pois muitos dispositivos vestíveis fazem a transmissão para a nuvem através do *smartphone* pessoal de pacientes, o que também pode configurar uma ameaça aos usuários. Como por exemplo, localização, câmera, contatos, etc. E para finalizar, ainda tem as vulnerabilidades de cada protocolo que podem ser exploradas por atacantes.

Algumas das premissas de segurança aplicadas a Internet das Coisas em saúde a destacar:

- **Confidencialidade:** trata-se de assegurar que as informações médicas do paciente não sejam compartilhadas sem autorização para tal, de acordo com preceitos de privacidade. No momento que a confidencialidade dos dados não for respeitada, um invasor pode interferir entre o receptor e o remetente efetuando a captura desses dados. Portanto, cabe ao desenvolvedor de tecnologia assegurar que os dados não serão interceptados. Isso pode ser feito através de algoritmos

criptográficos. Garantindo que as informações não serão divulgadas aos usuários, processos ou dispositivos, que não tenham sido autorizados para tal. Existe uma série de algoritmos criptográficos leves que podem ser executados em microcontroladores. Em (Zanon et al., 2022) apresenta-se uma comparação entre os algoritmos AES-256 CBC (*hardware* ESP32), PRESENT (*software*), SPECK (*software*), CLEFIA (*software*) em dois tipos de ataques: *man-in-the-middle* e espionagem. Além disso, foram definidas as métricas de *throughput* (vazão) e a latência para avaliar o impacto da criptografia leve na execução de exames com transmissão de sinais de eletrocardiograma.

- **Integridade:** A transmissão de dados sensíveis de pacientes de forma remota pode sofrer vazamento de informações. Por isso, o uso de camada intermediária de comunicação robusta (*fog ou edge computing*), como o recurso de dispositivos é limitado precisa contar com uma camada intermediária em condições de proteger a integridade das informações. Se houver alguma falha na arquitetura do sistema, o atacante pode realizar um ataque *man in the middle*, ou estimular o uso de *malwares*, acesso físico ao dispositivo e a injeção de código ou *firmware* malicioso ao dispositivo. As vantagens do blockchain neste escopo não se limitam ao compartilhamento seguro de dados do paciente entre plataformas, permitem aprimorar a interoperabilidade dos dados e a remoção de terceiros para controle de acesso (Qadri et al., 2020).
- **Não Repúdio:** É garantido a imutabilidade dos dados do tratamento médico e a certificação de não repúdio dos dados. Um dispositivo que coletou o eletrocardiograma de um paciente poderá enviar os dados e, posteriormente, alegar que não foi a origem desses dados. Por isso a imutabilidade e o não repúdio devem ser garantidos em todas as transações de dados no fluxo de transmissão dispositivo-servidor. Impede que uma entidade consiga negar a realização de determinada ação em uma interação anterior. Estas características também impulsionam o uso de blockchain para esta área.

Para ilustrar um dos casos possíveis e das diferentes possibilidades de vulnerabilidades relacionadas ao uso de dispositivos de Internet das Coisas em saúde, observe a Figura 8. Considere um vestível não invasivo que utiliza o *smartphone* como *gateway* para transmitir informações para o sistema de nuvem. Sem considerar quaisquer outros sistemas de camada intermediária, em uma rápida análise necessita ter a preocupação em garantir a segurança e privacidade em todos os níveis ou camadas da arquitetura. Para executar o aplicativo que coleta os dados no *smartphone*, o usuário precisa liberar o acesso a parte do dispositivo. Dependendo de como foi desenvolvida a aplicação poderão ter vulnerabilidades do sistema programado a ser explorado por pessoas mal intencionadas, ou até mesmo instalar algum *rootkit* ou *backdor* no dispositivo. Considerando a transmissão dos dados do vestível para o *smartphone*, que pode ser um BLE, ou mesmo um WIFI, existem as vulnerabilidades dos protocolos que podem ser exploradas ou permitir o acesso de terceiros mal intencionados. Além destes protocolos ainda tem o mecanismo de comunicação para transferir as informações para a nuvem, caso seja uma rede de celular existe um baixo nível de interceptação dos dados, mas se for outro tipo de rede haverá a necessidade de uso de algoritmos de

criptografia. E finalmente, neste exemplo fictício, ainda existe a necessidade de cuidar das informações que serão armazenadas na nuvem. Se o sistema utiliza um serviço fornecido por uma empresa de tecnologia da esfera mundial, possivelmente existirão as garantias de controle de acesso e segurança dos dados. Mas se for o caso de desenvolver um sistema de armazenamento próprio, um estudo aprofundado de como assegurar o acesso às informações, a confidencialidade e a integridade dos dados deverá ser feito.

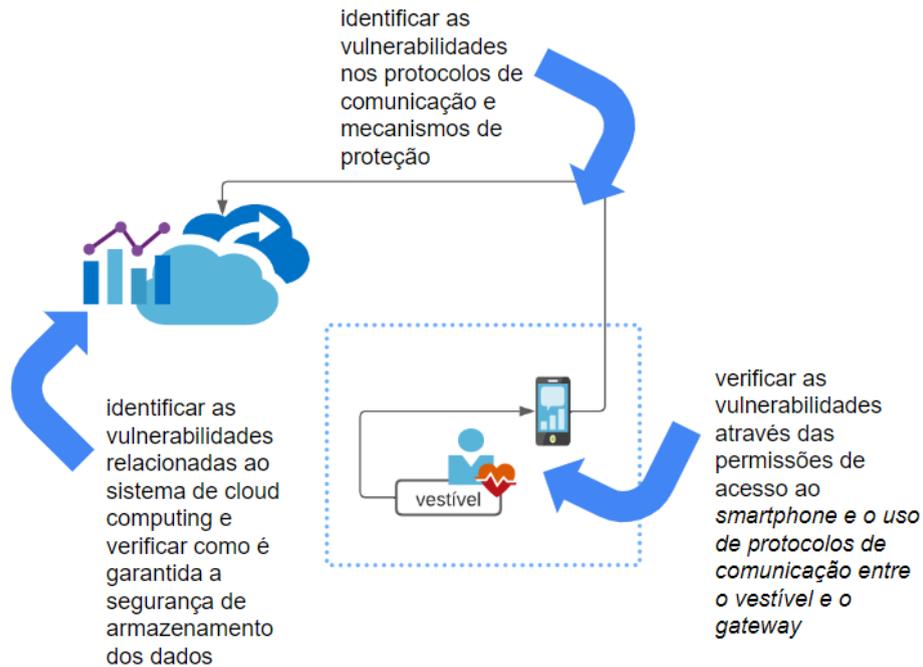


Figura 8- Esquema do uso de vestível e celular como gateway de acesso à Internet

Fonte: (próprio Autores)

1.4.3. Vestíveis e sensores para idosos

Com base nas pesquisas disponibilizadas e analisadas nos últimos anos, observou-se que algumas lacunas persistem. Uma delas que tem se destacado é a questão das interfaces de usuários para utilizar dispositivos e recursos de IoT em saúde. Imaginem a seguinte situação: colocar um vestível de pulso para monitorar os sinais vitais de um idoso que vive sozinho com os seus 77 anos de vida. Este vestível pode se tornar um problema porque precisa do cuidado e atenção de carregar a bateria. Pessoas idosas possuem declínio da sua capacidade cognitiva e portanto esquecem coisas com mais facilidade que outros adultos. Este tipo de vestível pode se tornar um fardo e portanto, a pessoa idosa considerar de não utilizar com a frequência que deveria. E para finalizar, este tipo de dispositivo com certeza não é o mais adequado para esta finalidade.

Existe a necessidade de pesquisadores em IoT em saúde desenvolver

dispositivos funcionais mas que sejam adequados a esta população em especial. Isso pode ser um dos motivos de entraves da tecnologia para este setor. E com o aumento da população idosa, existe a necessidade de se promover tecnologia para reduzir a ida destas pessoas aos hospitais. Portanto, ao desenvolver pesquisa de IoT em saúde para idosos, considere usar recursos de computação centrada em humanos. Outro ponto a destacar, é que além da perda cognitiva existem outros fatores que também dificultam o uso da tecnologia. Os idosos têm a visão e audição comprometida com o passar dos anos. Portanto, apresentar a solução de acesso às informações através de recursos visuais de celular talvez não atenda às suas necessidades.

1.4.4. Algoritmos explicáveis

Um outro desafio atrelado a ambientes inteligentes em saúde é tornar os sistemas de tomada de decisão mais confiáveis, reduzindo o risco de viés e apontando de uma forma explicativa quais soluções ou diagnósticos a partir de um determinado conjunto de dados. A Inteligência Artificial Explicável (do inglês, *Explainable Artificial Intelligence* - XAI) é um campo de pesquisa que visa tornar os modelos de IA transparentes e interpretáveis. É um recurso crucial para a implantação prática de modelos de IA principalmente em áreas de tomadas de decisão que envolvam seres humanos, como saúde, justiça e educação. A XAI pode auxiliar na explicabilidade de diferentes tipos de perfis, reduzir o número de vieses, explicar quais as características de um determinado modelo tiveram mais peso para a tomada de decisão do modelo. Portanto, esta área tem se dedicado a desenvolver formas de incluir explicabilidade e interpretabilidade em algoritmos de aprendizado de máquinas e aprendizado de máquinas profundo, de forma a promover algoritmos diferentes de algoritmos “caixa preta”. Ressalta-se que o avanço de sistemas inteligentes na área da saúde, principalmente na área de diagnóstico e análise de dados nos últimos anos, tem sido feito com base em algoritmos com esta característica. Analisam um volume de dados gigantesco e promovem a solução com base nestes dados, sem haver nestes resultados informações mais pessoais para cada indivíduo. Termos como compreensibilidade, inteligibilidade, interpretabilidade, explicabilidade e transparência passaram a ser pesquisados no sentido de incorporar ao uso de IA para determinadas áreas, evitando decisões equivocadas e presença de desvios (vieses) nestas soluções. A capacidade de um modelo de tornar sua função compreensível para humanos sem explicar sua estrutura interna ou meios algorítmicos, de representar seu conhecimento aprendido de uma forma compreensível por humanos, de explicar ou fornecer significado em termos compreensíveis e de ser compreensível por si só. Como por exemplo, o algoritmo de aprendizado de máquinas Máquina de Vetores de Suporte, ou em inglês, *Support Vector Machine* (SVM). Este algoritmo tem sido empregado como uma das técnicas de classificação de biomarcadores de estresse bem sucedida, em diversas pesquisas sobre estresse ocupacional analisadas nos últimos anos. Seria possível aplicar regras de explicação para este algoritmo tornando o resultado mais explicativo, ao invés de apenas treinar e apontar o desempenho do algoritmo frente ao treinamento da base de dados. Este tema e algumas alternativas que vêm sendo propostas foram discutidos no capítulo sobre biomarcadores para identificação de estresse (Morales et al., 2022). A

interpretabilidade também é essencial para sistemas de IA explicáveis. É um mecanismo para fornecer entendimento qualitativo entre as variáveis de entrada e a resposta do algoritmo.

Para exemplificar, a seguir é possível visualizar o resultado de aplicação de um algoritmo de *feature importance* sobre um conjunto de biomarcadores para estresse. Trata-se de uma técnica que calcula uma pontuação para as *features* de entrada para um determinado modelo — as pontuações representam a “importância” de cada *feature*. A pontuação mais alta significa que a *feature* tem um efeito maior no modelo que está sendo usado para prever uma determinada variável. Como pode ser observado no gráfico da Figura 9 os valores maiores têm maior influência no resultado do modelo, neste caso a média de temperatura e a taxa de variação cardíaca, e os valores médios e mínimos de cada um destes biomarcadores apresentam os maiores valores dentro do conjunto de dados usado no treinamento (TEMPR e HRR) (Fernandes, 2022).

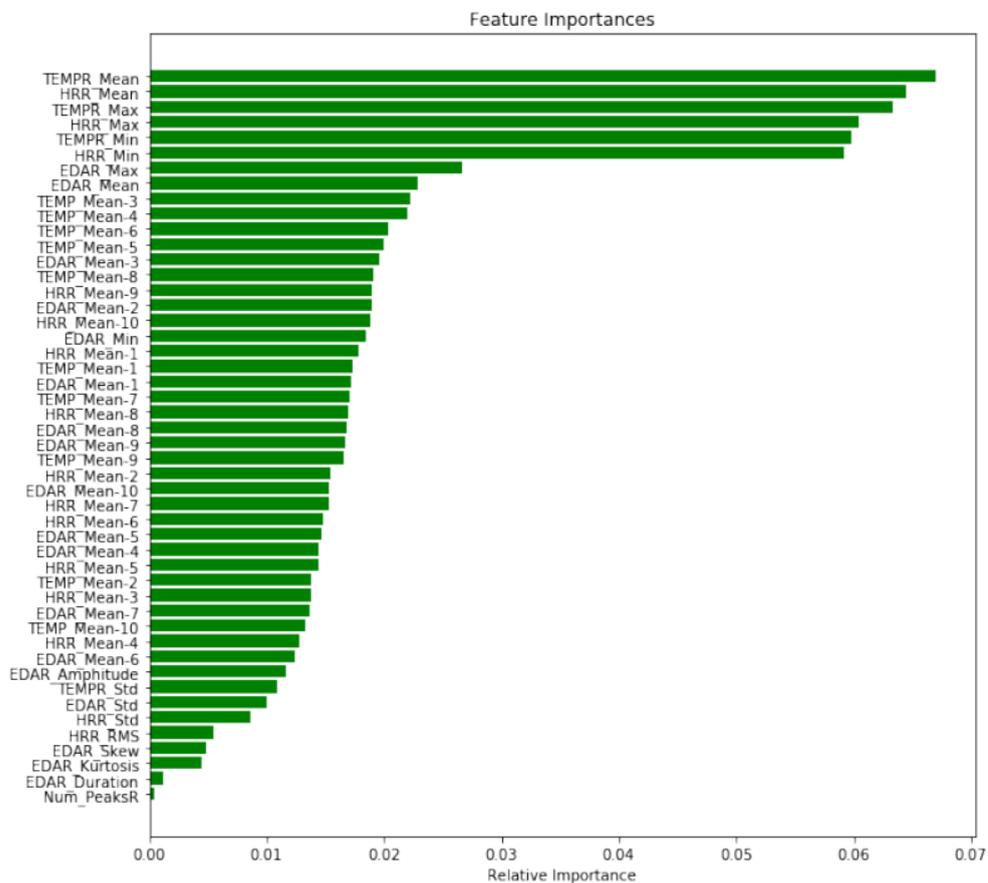


Figura 9 - Gráfico com resultado do algoritmo *Feature Importance*

Fonte: (Fernandes, 2022)

1.5. Conclusões

Conforme apresentado no capítulo, as áreas de Internet das Coisas e de Inteligência Artificial permanecem como áreas promissoras de mercado com significativo aporte financeiro para o desenvolvimento e aprimoramento de soluções. Quando trazemos estas áreas alinhadas ao contexto da saúde verificamos as inúmeras possibilidades de benefícios que os ambientes inteligentes e os sistemas inteligentes podem trazer a todo o ecossistema da saúde, e claro que com esta junção de áreas surgem desafios que precisam ser abordados com pesquisa tendo questões éticas e legislação como base.

A produção acadêmica sobre o tema Internet das Coisas e Saúde segue significativa, bem como a produção de patentes mundiais. Conforme descrito por (ROSA, SOUZA, SILVA, 2020), a tendência de inovações, observadas no estudo conduzido, destacava questões quanto a IoT e Saúde no âmbito da arquitetura de processos, sistemas e dispositivos relacionados a monitoramento remoto de pacientes através de sensores e plataformas inteligentes; redes de comunicação; armazenamento em nuvem; processamento, análise e gestão de dados de forma integrada e eficiente; segurança e controle de dados de saúde.

Ao adotar soluções baseadas em Internet das Coisas e Inteligência Artificial em diversos contextos, principalmente no contexto da saúde, surgem questões que necessitam ser pesquisadas e observadas, tais como proteção de dados do paciente, a Lei Geral de Proteção de Dados e cibersegurança dos sistemas. Estas questões se tornam ainda mais relevantes quando se trata de dispositivos médicos representados por equipamentos de *Internet of Medical Things*, que podem ter desempenho comprometido por questões de vulnerabilidade em redes de telecomunicação.

Em 2019, o governo federal apresentou o Plano Nacional de Internet das Coisas (IoT), instituído pelo Decreto nº 9.854, de 25 de junho de 2019 (Brasil, 2019), que tem como embasamento o estudo “Internet das Coisas: um plano de ação para o Brasil” consolidando uma visão estratégica sobre o tema para o território nacional (BNDES, 2018). Do ponto de vista regulatório, existem barreiras a serem solucionadas como por exemplo, a segurança e a privacidade de dados. O decreto nº 10.046, de 09 de outubro de 2019, assegura tratamento pautado nos princípios de privacidade, preservação da intimidade e respeito aos dados pessoais, nos termos da Lei Geral de Proteção de Dados (LGPD). No entanto, as arquiteturas que têm sido utilizadas, os dispositivos para a monitoração de dados e até mesmo os próprios protocolos de comunicação não deixam claro como lidar com este problema. A maioria dos protótipos que têm sido encontrados na literatura científica, nos últimos anos, não apresentam preocupação com a segurança e privacidade dos dados dos pacientes, ou usuários. Alguns trabalhos específicos sobre esta abordagem propõem algoritmos leves ou uso de blockchain para resolver o problema.

Questões éticas e os possíveis impactos sociais do uso da Inteligência Artificial no âmbito da saúde há muito já se apresenta nas pautas das reuniões. No ano de 2021 a Organização Mundial da Saúde (OMS) disponibilizou um robusto relatório sobre Ética e Governança da Inteligência Artificial para a Saúde²⁰, onde temas atuais são abordados, tais como, leis, políticas e princípios que se aplicam ao uso da inteligência artificial para a saúde, princípios éticos fundamentais para o uso da inteligência artificial na área da saúde, desafios éticos para o uso da inteligência artificial na área da saúde e os regimes de responsabilidade para a inteligência artificial para a saúde. O relatório destaca, de forma objetiva, os desafios e riscos éticos do uso da inteligência artificial na saúde, sendo apresentados os seis princípios chaves para garantir que a Inteligência Artificial atue pelo benefício público dos países.

No Brasil ainda não há uma legislação aprovada buscando regulamentar o uso da Inteligência Artificial no país, mas houve no ano de 2020 a criação do Projeto de lei (PL 21/2020²¹) que criou o marco legal para uso de inteligência artificial no Brasil, onde são estabelecidos os fundamentos, princípios e diretrizes para o desenvolvimento e a aplicação da Inteligência Artificial no Brasil. Atualmente o Senado Federal está analisando o Projeto de Lei nº 2338²², de 2023 que dispõe sobre o uso da inteligência artificial no Brasil. Cabe ressaltar que há a previsão de classificação de risco à sociedade da solução de Inteligência Artificial que se encontra em proposição, podendo ser de alto risco ou risco excessivo, conforme critérios propostos pela comissão responsável.

No contexto da Comunidade Européia, movimento semelhante busca regulamentar o uso da Inteligência Artificial, com base no documento “*Regulatory framework proposal on artificial intelligence*”²³. A proposta regulatória tem como objetivo fornecer aos desenvolvedores, implantadores e usuários de IA requisitos e obrigações claras em relação a usos específicos da IA. Semelhante ao Projeto de lei (PL 21/2020) brasileiro, também é previsto no framework níveis de risco percebidos nas soluções de IA, conforme Figura 10: Risco inaceitável, Risco alto, Risco limitado ou Risco mínimo ou nulo.

²⁰ <https://www.who.int/publications/i/item/9789240029200>

²¹ <https://www.camara.leg.br/propostas-legislativas/2236340>

²² <https://www25.senado.leg.br/web/atividade/materias/-/materia/157233>

²³

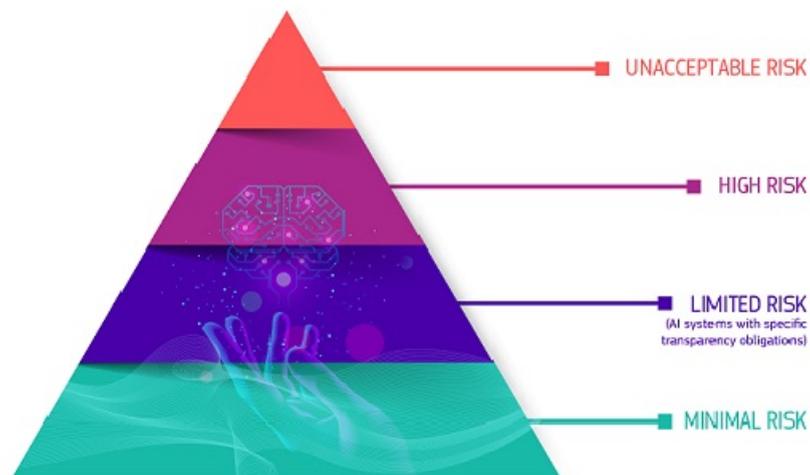


Figura 10 - Abordagem baseada em riscos para soluções de IA

Fonte: <https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai>

Por fim, cabe ressaltar a importância do movimento nacional e internacional visando regulamentar e assim, permitir o desenvolvimento das áreas de Internet das Coisas e Inteligência Artificial, de forma segura para a aplicação de soluções nos diversos contextos possíveis, principalmente para uma área tão sensível para o cidadão como a área da saúde.

Referências

- Abdel-Basset, M., Manogaran, G., Gamal, A., & Chang, V. (2019). A Novel Intelligent Medical Decision Support Model Based on Soft Computing and IoT. *IEEE Internet of Things Journal*, 4662(c), 1–1. <https://doi.org/10.1109/jiot.2019.2931647>
- Aceto, G., Persico, V., & Pescapé, A. (2018). The role of Information and Communication Technologies in healthcare: taxonomies, perspectives, and challenges. *Journal of Network and Computer Applications*, 107(July 2017), 125–154. <https://doi.org/10.1016/j.jnca.2018.02.008>
- Al-Qatatsheh, A., Morsi, Y., Zavabeti, A., Zolfagharian, A., Salim, N., Kouzani, A. Z., Mosadegh, B., & Gharaie, S. (2020). Blood pressure sensors: Materials, fabrication methods, performance evaluations and future perspectives. *Sensors (Switzerland)*, 20(16), 1–77. <https://doi.org/10.3390/s20164484>
- Al-Turjman, F., Nawaz, M. H., & Ullah, U. D. (2020). Intelligence in the Internet of Medical Things era: A systematic review of current and future trends. *Computer Communications*, 150(December 2019), 644–660. <https://doi.org/10.1016/j.comcom.2019.12.030>
- Andrews, J. G., Buzzi, S., Choi, W., Hanly, S. V., Lozano, A., Soong, A. C. K., &

- Zhang, J. C. (2014). What will 5G be? *IEEE Journal on Selected Areas in Communications*, 32(6), 1065–1082.
<https://doi.org/10.1109/JSAC.2014.2328098>
- Batmaz, Z., Yurekli, A., Bilge, A., & Kaleli, C. (2019). A review on deep learning for recommender systems: challenges and remedies. *Artificial Intelligence Review*, 52(1), 1–37. <https://doi.org/10.1007/s10462-018-9654-y>
- BNDES. (2017). *Internet das Coisas: um plano de ação para o Brasil - Relatório de Aprofundamento de Verticais – Saúde*.
https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/arquivosinternetdascoisas/fase3_7b_relatorio-de-aprofundamento-das-verticais-saude.pdf
- BNDES. (2018). *Plano de Ação do Estudo de Internet das Coisas. Produto 9a : Relatório Final do Estudo*.
https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/arquivosinternetdascoisas/fase3_9a_relatorio-final-do-estudo.pdf
- Brasil. (2019). *DECRETO Nº 9.854*. D.O.U. DE 26/06/2019, P. 10.
https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2019/decreto/d9854.html
- Cabrini, F. H., De Barros Castro Filho, A., Filho, F. V., Kofuji, S. T., & Moura, A. R. L. P. (2019). Helix SandBox: An open platform to fast prototype smart environments applications. *Proceedings of the 2019 IEEE 1st Sustainable Cities Latin America Conference, SCLA 2019*, 1–6.
<https://doi.org/10.1109/SCLA.2019.8905583>
- Castaneda, D., Esparza, A., Ghamari, M., Soltanpur, C., & Nazeran, H. (2018). A review on wearable photoplethysmography sensors and their potential future applications in health care. *International Journal of Biosensors & Bioelectronics*, 4(4), 195. <https://doi.org/10.15406/IJBSBE.2018.04.00125>
- Chalabianloo, N., Said, Y., Umair, M., & Sas, C. (2022). Application level performance evaluation of wearable devices for stress classification with explainable AI. *Pervasive and Mobile Computing*, 87, 101703.
<https://doi.org/10.1016/j.pmcj.2022.101703>
- Cieslak, F. A. M. (2021). *Análise do protocolo 6LowPAN/RPL para simulação de redes de sensores voltadas sem fio voltadas ao IoT Healthcare utilizando o COOJA/Contiki* [Araranguá, SC].
<https://repositorio.ufsc.br/handle/123456789/228721>
- Cocian, L. F. E., Morales, A. S., & Schneider, I. J. C. (2023). Internet of Things as support to reduce hospital errors related to medication administration. *Research, Society and Development*, 12(3), e6312340425–e6312340425.

<https://doi.org/10.33448/RSD-V12I3.40425>

- Cordeiro, B. M. de O. S. (2022). *Redes IoT Baseadas em SDN e Dirigidas por Intenções* [Universidade Federal de Goiás (UFG)].
<https://repositorio.bc.ufg.br/tede/bitstream/tede/12211/3/Dissertação - Bruna Michelly de Oliveira Silva Cordeiro - 2022.pdf>
- Deo, R. C. (2015). Machine Learning in Medicine HHS Public Access. *Circulation*, 132(20), 1920–1930.
<https://doi.org/10.1161/CIRCULATIONAHA.115.001593>
- Devi, D. H., Duraisamy, K., Armghan, A., Alsharari, M., Aliqab, K., Sorathiya, V., Das, S., & Rashid, N. (2023). 5G Technology in Healthcare and Wearable Devices: A Review. *Sensors 2023, Vol. 23, Page 2519*, 23(5), 2519.
<https://doi.org/10.3390/S23052519>
- Dunn, J., Runge, R., & Snyder, M. (2018). Wearables and the medical revolution. *Personalized Medicine*, 15(5), 429–448.
<https://doi.org/10.2217/pme-2018-0044>
- Fernandes, M. S. (2022). *Inteligência Artificial Explicável aplicada a Aprendizado de Máquina: Um estudo para Identificar Estresse Ocupacional em Profissionais da Saúde*. Universidade Federal de Santa Catarina. Disponível em: <https://repositorio.ufsc.br/handle/123456789/243462> Acessado em: 19 de maio de 2023.
- Golledge, J., Fernando, M., Lazzarini, P., Najafi, B., & Armstrong, D. G. (2020). The Potential Role of Sensors, Wearables and Telehealth in the Remote Management of Diabetes-Related Foot Disease. *Sensors*, 20(4527), 1–15.
<https://doi.org/10.3390/s20164527>
- Gralha, S. R., Fleig, T., Dihl, F. V., Morales, A. S., & Cazella, S. C. (2022). Tecnologias de IoT na área da saúde para idosos: um mapeamento sistemático. *Research, Society and Development*, 11(7), e49111730453.
<https://doi.org/10.33448/rsd-v11i7.30453>
- Habibzadeh, H., Dinesh, K., Rajabi Shishvan, O., Boggio-Dandry, A., Sharma, G., & Soyata, T. (2020). A Survey of Healthcare Internet of Things (HIoT): A Clinical Perspective. *IEEE Internet of Things Journal*, 7(1), 53–71.
<https://doi.org/10.1109/JIOT.2019.2946359>
- Habibzadeh, H., Soyata, T., Kantarci, B., Boukerche, A., & Kaptan, C. (2018). Sensing, communication and security planes: A new challenge for a smart city system design. *Computer Networks*, 144, 163–200.
<https://doi.org/10.1016/j.comnet.2018.08.001>
- Islam, M. M., & Bhuiyan, Z. A. (2023). An Integrated Scalable Framework for Cloud and IoT based Green Healthcare System. *IEEE Access*, 11(March), 22266–22282. <https://doi.org/10.1109/ACCESS.2023.3250849>

- ITU (Ed.). (2012). Recommendation ITU-T Y.2060: An overview of internet of things. In *SERIES Y: GLOBAL INFORMATION INFRASTRUCTURE, INTERNET PROTOCOL ASPECTS AND NEXT-GENERATION NETWORKS Next Generation Networks – Frameworks and functional architecture models* (pp. 1–22). International Telecommunication Union (ITU).
- ITU. (2014). Recommendation ITU-T Y.2066 Common requirements of the Internet of things. In ITU (Ed.), *SERIES Y: GLOBAL INFORMATION INFRASTRUCTURE, INTERNET PROTOCOL ASPECTS AND NEXT-GENERATION NETWORKS. Next Generation Networks – Frameworks and functional architecture models* (ITU, p. 32). ITU. <http://handle.itu.int/11.1002/1000/12169>
- ITU. (2019). Recommendation ITU-T Y.4460: Architectural reference models of devices for Internet of things applications. In ITU (Ed.), *GLOBAL INFORMATION INFRASTRUCTURE, INTERNET PROTOCOL ASPECTS, NEXT-GENERATION NETWORKS, INTERNET OF THINGS AND SMART CITIES GLOBAL* (ITU, pp. 1–26). International Telecommunication Union (ITU). <http://handle.itu.int/11.1002/1000/11830-en>
- Kakhi, K., Alizadehsani, R., Kabir, H. M. D., Khosravi, A., Nahavandi, S., & Acharya, U. R. (2022). The internet of medical things and artificial intelligence: trends, challenges, and opportunities. *Biocybernetics and Biomedical Engineering*, 42(3), 749–771. <https://doi.org/10.1016/J.BBE.2022.05.008>
- Kashyap, V., Kumar, A., Kumar, A., & Hu, Y. C. (2022). A Systematic Survey on Fog and IoT Driven Healthcare: Open Challenges and Research Issues. *Electronics (Switzerland)*, 11(17), 1–25. <https://doi.org/10.3390/electronics11172668>
- Koydemir, H. C., & Ozcan, A. (2018). Wearable and Implantable Sensors for Biomedical Applications. *Annual Review of Analytical Chemistry*, 11, 127–146. <https://doi.org/10.1146/annurev-anchem-061417-125956>
- Lu, T., Ji, S., Jin, W., Yang, Q., Luo, Q., & Ren, T. (2023). Biocompatible and Long-Term Monitoring Strategies of Wearable, Ingestible and Implantable Biosensors: Reform the Next Generation Healthcare. *Sensors (Basel, Switzerland)*, 23(6), 2991(1-37).
- Marques, G., Pitarma, R., Garcia, N. M., & Pombo, N. (2019). Internet of things architectures, technologies, applications, challenges, and future directions for enhanced living environments and healthcare systems: A review. *Electronics (Switzerland)*, 8(10), 1–27. <https://doi.org/10.3390/electronics8101081>
- Marques, G., Miranda, N., Bhoi, A. K., Garcia-zapirain, B., Hamrioui, S., & Díez, I. de la T. (2020). Internet of things and enhanced living environments: Measuring and mapping air quality using cyber-physical systems and mobile computing technologies. *Sensors (Switzerland)*, 20(3), 1–20. <https://doi.org/10.3390/s20030720>

- Marques, G., Saini, J., Dutta, M., Singh, P. K., & Hong, W. C. (2020). Indoor air quality monitoring systems for enhanced living environments: A review toward sustainable smart cities. *Sustainability (Switzerland)*, *12*(10). <https://doi.org/10.3390/SU12104024>
- Minh Dang, L., Piran, M. J., Han, D., Min, K., & Moon, H. (2019). A survey on internet of things and cloud computing for healthcare. *Electronics (Switzerland)*, *8*(7), 1–49. <https://doi.org/10.3390/electronics8070768>
- Morales, A. S., Ourique, F. de O., & Cazella, S. C. (2021). A Comprehensive Review on the Challenges for Intelligent Systems Related with Internet of Things for Medical Decision. *Studies in Fuzziness and Soft Computing*, *410*, 221–240. https://doi.org/10.1007/978-3-030-70111-6_11
- Morales, A. S., de Oliveira Ourique, F., Morás, L. D., & Cazella, S. C. (2022). Exploring Interpretable Machine Learning Methods and Biomarkers to Classifying Occupational Stress of the Health Workers. *Intelligent Systems Reference Library*, *121*, 105–124. https://doi.org/10.1007/978-3-030-97516-6_6/COVER/
- Morales, A., Barbosa, M., Morás, L., Cazella, S. C., Sgobbi, L. F., Sene, I., & Marques, G. (2022). Occupational Stress Monitoring Using Biomarkers and Smartwatches: A Systematic Review. *Sensors 2022, Vol. 22, Page 6633*, *22*(17), 6633. <https://doi.org/10.3390/S22176633>
- Morales, A. S.; Schneider, I. J. C. ; Ourique, F. O. ; Cazella, S. C. (*in press*). Roadmap to the elderly enhanced living and care environments: applications and challenges on the Internet of Things domain. *Advances in Computers*, Elsevier.
- Muhammed, T., Mehmood, R., Albeshri, A., & Katib, I. (2018). UbeHealth: A personalized ubiquitous cloud and edge-enabled networked healthcare system for smart cities. *IEEE Access*, *6*, 32258–32285. <https://doi.org/10.1109/ACCESS.2018.2846609>
- Nilson, E.A.F., Andrade R.C.S., Brito D.A., Oliveira M.L. (2018). Custos atribuíveis à obesidade, hipertensão e diabetes no Sistema Único de Saúde, Brasil, 2018. *Rev Panam Salud Publica*. 2020;44:e32. <https://doi.org/10.26633/RPSP.2020.32>
- Nasajpour, M., Pouriye, S., Parizi, R. M., Dorodchi, M., Valero, M., & Arabnia, H. R. (2020). Internet of Things for Current COVID-19 and Future Pandemics: an Exploratory Study. *Journal of Healthcare Informatics Research*, *4*(4), 325–364. <https://doi.org/10.1007/s41666-020-00080-6>
- OMS. (2015). *Relatório Mundial de Envelhecimento e Saúde*. <https://sbgg.org.br/wp-content/uploads/2015/10/OMS-ENVELHECIMENTO-2015-port.pdf>

- Perwej, Y., Akhtar, N., Neha Kulshrestha, & Mishra, P. (2022). A Methodical Analysis of Medical Internet of Things (MIoT) Security and Privacy in Current and Future Trends. *Journal of Emerging Technologies and Innovative Research*, 9(1), d346–d371.
<https://hal.archives-ouvertes.fr/hal-03540225><https://hal.archives-ouvertes.fr/hal-03540225/document>
- Prieto-Avalos, G., Cruz-Ramos, N. A., Alor-Hernández, G., Sánchez-Cervantes, J. L., Rodríguez-Mazahua, L., & Guarneros-Nolasco, L. R. (2022). Wearable Devices for Physical Monitoring of Heart: A Review. *Biosensors*, 12(5), 1–31.
<https://doi.org/10.3390/bios12050292>
- Qadri, Y. A., Nauman, A., Zikria, Y. Bin, Vasilakos, A. V., & Kim, S. W. (2020). The Future of Healthcare Internet of Things: A Survey of Emerging Technologies. *IEEE Communications Surveys & Tutorials*, c, 1–1.
<https://doi.org/10.1109/comst.2020.2973314>
- Qureshi, H. N., Manalastas, M., Farooq, M. U. Bin, Imran, A., Liu, Y., & Kalaa, M. O. Al. (2023). 5G-Enabled Healthcare in Mobile Scenarios: Challenges and Implementation Considerations. *IEEE Network*.
<https://doi.org/10.1109/MNET.125.2200243>
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347–1358.
<https://doi.org/10.1056/NEJMra1814259>
- Rayan, Z., Alfonse, M., & Salem, A. B. M. (2018). Machine Learning Approaches in Smart Health. *Procedia Computer Science*, 154(1985), 361–368.
<https://doi.org/10.1016/j.procs.2019.06.052>
- RNP (2023) Relatório Técnico: Visão do Futuro da Saúde Digital. , Rede nacional de Pesquisa/RNP/Comitê Técnico de Prospecção em Saúde Digital (CT-SD). Org.: Moro , C.; Amaro, E. ; Branco , G.; Araujo , G. B.; Moura, L. A. ; Portilho, L.; Messina, L. A.; Espinola , M. M. G. ; Lopes, P. R. L. Disponível em :
https://wiki.rnp.br/download/attachments/131176955/CT-SD_Visao_de_Futuro_versão2022.pdf?version=3&modificationDate=1678821886000&api=v2.
 Acessado em : 08/04/2023
- Rodríguez-Rodríguez, I., Rodríguez, J.V. , & Campo-Valera, M. (2023). Applications of the Internet of Medical Things to Type 1 Diabetes Mellitus, *Electronics* 12, no. 3: 756. <https://doi.org/10.3390/electronics12030756>
- Romanholo, P. V. V., Razzino, C. A., Raymundo-Pereira, P. A., Prado, T. M., Machado, S. A. S., & Sgobbi, L. F. (2021). Biomimetic electrochemical sensors: New horizons and challenges in biosensing applications. *Biosensors and Bioelectronics*, 185, 113242. <https://doi.org/10.1016/J.BIOS.2021.113242>

- Rosa, C.M., Souza, P.A.R., Silva, J.M.(2020) Inovação em saúde e internet das coisas (IoT): Um panorama do desenvolvimento científico e tecnológico. *Perspectivas em Ciência da Informação*. N.25, número 3, p. 164-181. Disponível em: <https://doi.org/10.1590/1981-5344/3885>
- Sadoughi, F., Behmanesh, A., & Sayfour, N. (2020). Internet of things in medicine: A systematic mapping study. *Journal of Biomedical Informatics*, 103(January), 103383. <https://doi.org/10.1016/j.jbi.2020.103383>
- Scarpato, N., Pieroni, A., Di Nunzio, L., & Fallucchi, F. (2017). E-health-IoT universe: A review. *International Journal on Advanced Science, Engineering and Information Technology*, 7(6), 2328–2336. <https://doi.org/10.18517/ijaseit.7.6.4467>
- Seneviratne, S., Hu, Y., Nguyen, T., Lan, G., Khalifa, S., Thilakarathna, K., Hassan, M., & Seneviratne, A. (2017). A Survey of Wearable Devices and Challenges. *IEEE Communications Surveys and Tutorials*, 19(4), 2573–2620. <https://doi.org/10.1109/COMST.2017.2731979>
- Serhani, M. A., El Kassabi, H. T., Ismail, H., & Navaz, A. N. (2020). ECG monitoring systems: Review, architecture, processes, and key challenges. *Sensors (Switzerland)*, 20(6). <https://doi.org/10.3390/s20061796>
- Shetty, A., Kaur, S., & HJ, Y. (2023). Future Well-Being with Digital Health Technologies. *Journal Healthcare Treatment Development*, 31, 1–8. <https://doi.org/10.55529/jhtd.31.1.8>
- Silva, H. H. da, Rocha, M., Martins, G. G. V., Fernandes, M., Morales, A. S., & Panisson, A. (2023). Perspectivas da Utilização de Teoria da Mente para o Reconhecimento e Intervenção de Estresse Ocupacional. *Anais Do Computer on the Beach 2023*, 487–489. <https://doi.org/10.14210/cotb.v14.p487-489>
- Tian, S., Yang, W., Grange, J. M. Le, Wang, P., Huang, W., & Ye, Z. (2019). Smart healthcare: making medical care more intelligent. *Global Health Journal*, 3(3), 62–65. <https://doi.org/10.1016/j.glohj.2019.07.001>
- Tiffin, P. A., & Paton, L. W. (2018). Rise of the machines? Machine learning approaches and mental health: Opportunities and challenges. *British Journal of Psychiatry*, 213(3), 509–510. <https://doi.org/10.1192/bjp.2018.105>
- Yang, G., Deng, J., Pang, G., Zhang, H., Li, J., Deng, B., Pang, Z., Xu, J., Jiang, M., Liljeberg, P., Xie, H., & Yang, H. (2018). An IoT-Enabled Stroke Rehabilitation System Based on Smart Wearable Armband and Machine Learning. *IEEE Journal of Translational Engineering in Health and Medicine*, 6, 1–10. <https://doi.org/10.1109/JTEHM.2018.2822681>
- Zanon, V. R., Romancini, E. M. R., Ourique, F. de O., & Morales, A. S. (2021). Dispositivo com Interface Vestível para a Aquisição, Processamento e

Transmissão do Sinal Cardíaco em Exame de Eletrocardiograma. *Anais Do Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, 48–59.
<https://doi.org/10.5753/SBCAS.2021.16052>

Zanon, V. R., Romancini, E. M. R., Manoel, B. de E., Lau, J., Ourique, F. de O., & Morales, A. S. (2022). Avaliação experimental de uma camada de segurança implementada em dispositivo vestível cardíaco para Internet das Coisas Médicas. *Anais Do Simpósio Brasileiro de Segurança Da Informação e de Sistemas Computacionais (SBSEG)*, 97–110.
<https://doi.org/10.5753/SBSEG.2022.224659>

Zanon, V. R., Romancini, E. M. R., Ourique, F. de O., & Morales, A. S. (2022). Wearable technology for electrocardiogram and vectocardiogram using the Dower Transformation. | Zanon | Journal of Health Informatics. *Journal of Health Informatics*, 14(1), 3–10.
<http://www.jhi-sbis.saude.ws/ojs-jhi/index.php/jhi-sbis/article/view/889>

Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1).

Wu, J., Nan, Y., Kumar, V., Tian, D., Bianchi, A., Payer, M., & Xu, D. (2020). BLESAs: Spoofing attacks against reconnections in bluetooth low energy. *WOOT 2020 - 14th USENIX Workshop on Offensive Technologies, Co-Located with USENIX Security 2020*, 8, 8.
<https://dl.acm.org/doi/abs/10.5555/3488877.3488885>

Capítulo

2

Aprendizado de Máquina Supervisionado para Séries Temporais na Área da Saúde

Diego F. Silva, Guilherme G. Arcencio, José Gilberto B. M. Júnior, Vinícius M. A. de Souza, Yuri G. A. da Silva

Abstract

Machine Learning for time series is the knowledge domain that aims at creating models from data collected over time. This type of data is especially interesting for the healthcare field, as it represents measurements of physiological signals such as electrocardiography and photoplethysmography, among other clinical exams. Models obtained through Machine Learning algorithms in this context can assist healthcare professionals in disease diagnosis and constant patient monitoring. This chapter presents techniques for handling temporal healthcare data from theoretical and practical perspectives. In addition to discussing preprocessing and feature extraction, it addresses the two main Machine Learning tasks for this context: classification and extrinsic regression.

Resumo

O Aprendizado de Máquina para séries temporais é o domínio do conhecimento relacionada à criação de modelos a partir de dados coletados ao longo do tempo. Esse tipo de dados é especialmente interessante para a Saúde, uma vez que é a forma de representar medições de sinais fisiológicos, como eletrocardiografia e fotopletismografia, além de outros exames clínicos. Modelos obtidos por algoritmos de Aprendizado de Máquina, nesse contexto, podem auxiliar profissionais de saúde no diagnóstico de doenças e no monitoramento constante de pacientes. Este capítulo apresenta técnicas para lidar com dados temporais para a área da saúde, sob os pontos de vista teórico e prático. Além de discutir a respeito de pré-processamento e extração de características, aborda as duas principais tarefas de Aprendizado de Máquina para este contexto: classificação e regressão extrínseca.

2.1. Introdução

Com o desenvolvimento de novas tecnologias como veículos autônomos, cidades inteligentes e a Internet das Coisas, sensores móveis se tornaram cada vez mais baratos, precisos, pequenos e eficientes em uso de bateria e capacidade de processamento. Além disso, o barateamento de meios de armazenamento e o surgimento de algoritmos capazes de processar grandes volumes de dados permite, cada vez mais, a coleta de dados medidos ao longo do tempo em variados domínios do conhecimento, como saúde, economia e monitoramento ambiental. Como resultado, aplicações que coletam grandes volumes de dados temporais usando sensores surgem em diferentes domínios do conhecimento [Ang and Seng 2016, Yeh et al. 2018, Hu et al. 2019].

Especialmente, a área da Saúde conta com variadas formas de obtenção de dados temporais, bem como diferentes aplicações. Por exemplo, sinais relativos à atividade cardiorrespiratória podem auxiliar na prevenção de ataques cardíacos [Alsuliman et al. 2020] e sinais de unidades de medida inercial, como acelerômetros, pode auxiliar na identificação de doenças como o mal de Parkinson [El Maachi et al. 2020].

Dentre as fontes de dados temporais, é possível citar equipamentos para registro de sinais fisiológicos, como oxímetros e eletrocardiógrafos. A Figura 2.1 ilustra um fotopletismógrafo de dedo e um gráfico da variação de luz coletada por ele ao longo do tempo.

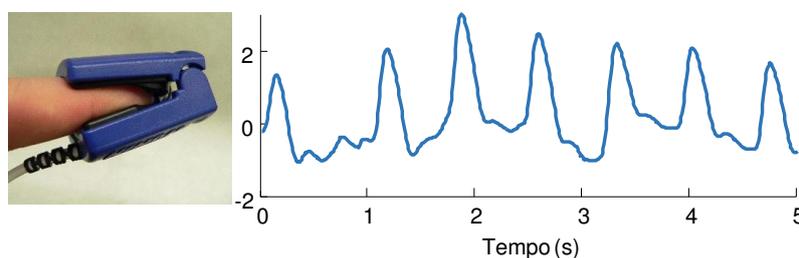


Figura 2.1. Um oxímetro de dedo (*esquerda*) e uma série temporal de fotopletismografia de 5 segundos obtida com esse aparelho (*direita*). Adaptado de [Silva et al. 2018].

Enquanto esses dados podem ser utilizados para uma infinidade de aplicações, como o monitoramento de sinais vitais e auxílio ao diagnóstico, grande parte do volume de séries temporais coletadas acaba sendo subutilizada. O Aprendizado de Máquina oferece um conjunto de técnicas altamente eficazes para melhor aproveitar esses dados em aplicações práticas. Nesse contexto, este capítulo aborda conceitos e técnicas de Aprendizado de Máquina aplicados a séries temporais na área da Saúde¹. Dado o amplo escopo desse domínio, o foco deste trabalho está nas tarefas de classificação e regressão extrínseca de séries temporais. Além disso, são discutidas diversas aplicações desse tipo de dados na área da Saúde, com especial ênfase em dados de eletrocardiografia e fotopletismografia.

¹Há uma parte prática neste capítulo, em que se utiliza Python e algumas bibliotecas escritas para essa linguagem de programação. Portanto, espera-se que os leitores possuam um conhecimento prévio básico sobre a linguagem. Além disso, este capítulo apresenta apenas a parte principal dos códigos utilizados. Para melhor detalhamento de cada passo, disponibilizamos *notebooks* no repositório GitHub <https://github.com/diegofurts/SBCAS2023>.

A introdução aos conceitos básicos de séries temporais e Aprendizado de Máquina, bem como a discussão de algumas aplicações na Saúde, é realizada na Seção 2.2. Nela, também são brevemente discutidas a decomposição de uma série temporal e o domínio de frequências. A seguir, na Seção 2.3, são apresentados conceitos teóricos e práticos do pré-processamento de séries temporais, com ênfase na remoção de tendência, interpolação, filtragem e extração de características. Como a classificação e a regressão extrínseca possuem muitos conceitos em comum, bem como diversos algoritmos baseados em premissas similares, esses conceitos e alguns algoritmos são apresentados juntos, na Seção 2.4. Por fim, a Seção 2.2.2 apresenta alguns estudos de caso práticos, utilizando ferramentas de código aberto para realizar as tarefas estudadas utilizando dados de eletrocardiograma e fotopleletismografia.

2.2. Conceitos Básicos

Com o constante aumento na geração, coleta e armazenamento de séries temporais, também é crescente o interesse em algoritmos capazes de realizar previsões e análises avançadas com base nesse tipo de dados. Este capítulo aborda o uso do Aprendizado de Máquina em séries temporais, com maior foco em aplicações na área da Saúde. Nesse contexto, o objetivo principal desta seção é apresentar os conceitos fundamentais relacionados às séries temporais e ao Aprendizado de Máquina, além de discutir algumas aplicações específicas na área da Saúde.

2.2.1. Séries Temporais

O principal objeto deste curso são séries temporais, com foco naquelas originadas de aplicações relacionadas à Saúde. Esse tipo de dado tem se destacado em uma infinidade de aplicações, em áreas como economia, finanças, meteorologia, engenharia e ciências sociais. De forma geral, esse tipo de dados é utilizado em aplicações em que se há o interesse de realizar previsões relacionadas a um comportamento no tempo. Por exemplo, a observação de um instante da resposta de um eletrodo fixado na pele de um paciente não é capaz de indicar informações relevantes sobre sua saúde. Por exemplo, uma única observação de um eletrodo fixado na pele de um paciente pode não fornecer informações relevantes sobre sua saúde. No entanto, quando essa resposta é observada ao longo de um intervalo de tempo, ela pode ser utilizada para diagnósticos, como a detecção de irregularidades no ritmo cardíaco por eletrocardiograma [Becker 2006].

Formalmente, uma série temporal S é uma sequência de n valores ordenados, conforme a Equação 1.

$$S = (s_1, s_2, \dots, s_n), \text{ tal que } s_t \in \mathbb{R}^d \forall t \in [1, n] \quad (1)$$

Seguindo essa definição, quando $d = 1$, a série temporal é chamada unidimensional ou univariada. Caso contrário, ou seja, $d > 1$, tem-se uma série temporal multidimensional ou multivariada. Por exemplo, a fotopleletismografia, observada isoladamente, é representada por uma série temporal univariada. Ao ser observada junto a outros parâmetros, como eletrocardiograma e pressão arterial, observa-se uma série temporal multivariada.

Cada um dos valores s_t é referido como uma observação do fenômeno que gera esse dado temporal. Usualmente, assume-se que duas observações consecutivas são igualmente espaçadas no tempo. Essa suposição é comum, pois os dispositivos de coleta normalmente medem o valor aferido em uma frequência constante. Caso essa suposição não seja verdadeira, o procedimento usual é utilizar alguma técnica de interpolação dos dados, uma vez que os algoritmos desenvolvidos para séries temporais comumente assumem essa premissa.

Por fim, uma subsequência da série temporal é um subconjunto contíguo de suas observações. Formalmente, uma subsequência de comprimento m é definida pela Equação 2.

$$\mathbb{S} = (s_i, s_{i+1}, \dots, s_{i+m-1}), \text{ tal que } s_i \in \mathbb{R}^d \forall t \in [1, n - m] \quad (2)$$

A Figura 2.2 apresenta a forma gráfica de uma série temporal obtida por meio de um eletrocardiograma. Por simplicidade de representação, por vezes será desconsiderada a escala do tempo real no eixo temporal neste capítulo, exibindo-se os índices das observações no eixo. Isso se deve ao fato de que será considerado que todas as séries temporais de um mesmo conjunto de dados foram amostradas na mesma frequência, ou seja, possuam o mesmo número de observações por segundo. Para os algoritmos que serão estudados, o valor real do eixo temporal não é utilizado. Porém, caso seja relevante observar o tempo do evento, a conversão de unidades é bastante simples.

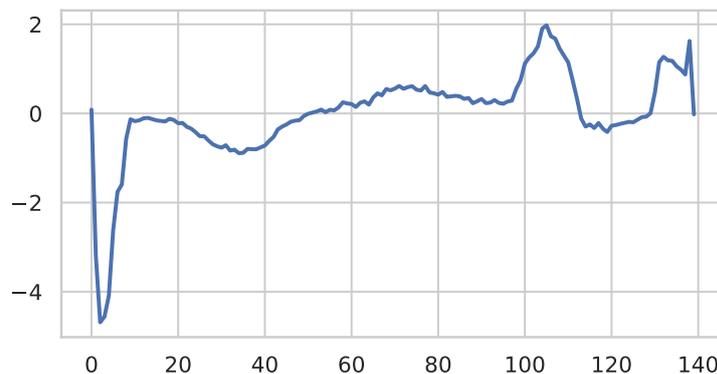


Figura 2.2. Exemplo de uma série temporal univariada com 140 observações, extraída do conjunto de dados ECG5000 [Dau et al. 2018].

Enquanto a Figura 2.2 apresenta uma série univariada contendo apenas um evento, a Figura 2.3 exibe uma subsequência de 500 observações de uma série temporal, que contém dados de uma eletrocardiografia (ECG) e uma fotopletismografia (PPG), retirada do repositório de dados para regressão extrínseca de séries temporais [Tan et al. 2020].

Esses dois conjuntos de dados representam exemplos de séries temporais na área da Saúde. Há diversas aplicações nesse contexto, sendo algumas delas discutidas a seguir.

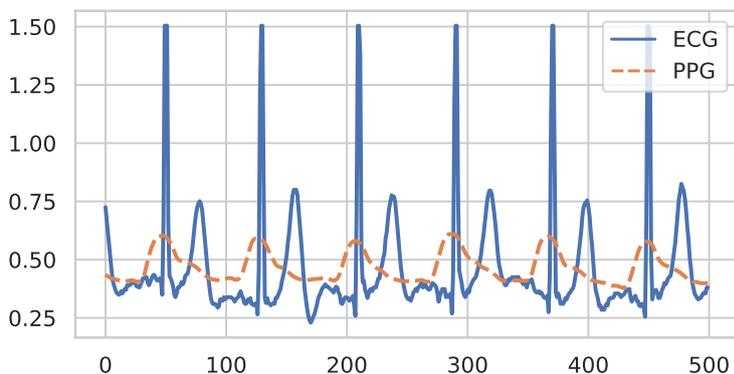


Figura 2.3. Exemplo de uma série temporal multivariada com 500 observações, extraída do conjunto de dados BIDMC32HR [Tan et al. 2020].

2.2.2. Utilização de Séries Temporais na Saúde

As séries temporais são utilizadas há décadas em aplicações no domínio da Saúde. Porém, observa-se um grande crescimento no interesse por esse tipo de dados em anos recentes. A utilização de Aprendizado de Máquina para dados temporais têm sido aplicado da previsão de ocupação de leitos e tempo de permanência dos pacientes até como auxílio a diagnósticos em diferentes especialidades, como doenças cardiovasculares, renais e respiratórias [Morid et al. 2023].

Uma gama de aplicações vêm se tornando cada vez mais comuns em dados obtidos por meio de eletrocardiografia [Hong et al. 2020]. Dentre essas aplicações, pode-se exemplificar a detecção de apneia do sono [Salari et al. 2022] e a identificação de batimentos cardíacos anômalos, como arritmias [Ebrahimi et al. 2020].

Outro dado que tem sido comumente utilizado em tarefas de Aprendizado de Máquina para séries temporais em Saúde é a fotopletismografia, que consiste na variação da resposta óptica baseada em uma fonte de luz (geralmente um diodo emissor de luz - LED) voltada para a pele. Aparelhos para se realizar a fotopletismografia se tornaram comuns durante o período da pandemia de COVID-19, pois é uma forma precisa de se estimar a oxigenação no sangue de forma não invasiva. Além desse parâmetro, estudos mostram que o Aprendizado de Máquina também pode ser utilizado para se estimar pressão sanguínea [El-Hajj and Kyriacou 2020], detectar ansiedade [Perpetuini et al. 2021], hipertensão [Martinez-Ríos et al. 2022], fibrilação atrial [Pereira et al. 2020], entre outras, a partir de dados de fotopletismografia.

É importante ressaltar que se percebe em novos produtos e na literatura recente haver um crescente interesse no desenvolvimento de novas tecnologias e aprimoramento da comunicação na medicina. A situação social, como o grande número de pessoas que moram em áreas vulneráveis ou remotas, tendo dificuldade de acesso a diversos serviços de saúde, e eventos recentes, como a pandemia de COVID-19, tem estimulado o crescimento do uso da telemedicina e o desenvolvimento de ferramentas para monitoramento de pacientes.

Nesse contexto, encontram-se as ferramentas de *mobile health* (mHealth). A Organização Mundial da Saúde (OMS) definiu mHealth como “prática médica e de saúde pública suportada por dispositivos móveis, como telefones celulares, dispositivos de monitoramento de pacientes, assistentes digitais pessoais e outros dispositivos sem fio” (tradução nossa) [WHO 2011]. Alguns dispositivos relevantes para a saúde móvel são os *smartwatches* e os *smartphones*. Por meio deles, é possível obter dados (comumente séries temporais) que podem ser utilizados para uma infinidade de aplicações.

Por exemplo, acelerômetros podem ser utilizados para o monitoramento de pacientes com doença de Parkinson [Lee et al. 2022]. Mas, além disso, vale ressaltar que os sensores contidos nesses dispositivos móveis podem simular diferentes equipamentos médicos. Por exemplo, a câmera de um *smartphone* pode ser utilizada para simular uma fotoplestimografia [Mazzu-Nascimento et al. 2020] e seu microfone pode ser aplicado como fonocardiografia [Thoms et al. 2017]. Por esse e outros motivos, vivemos um cenário muito favorável ao crescimento da demanda por técnicas de Aprendizado de Máquina para séries temporais na área da Saúde.

Porém, para melhor aproveitar esse cenário, é preciso compreender melhor as características dos dados que estão sendo coletados e como utilizar diferentes técnicas para garantir a qualidade dos dados e das tarefas executadas a partir deles.

2.2.3. Componentes de uma série temporal

Uma série temporal pode ser decomposta em diferentes propriedades que definem sua variação no tempo. Em muitos casos, a decomposição de uma série pode ser fundamental para uma análise aprofundada dos dados. Ainda, remover a influência de uma ou mais dessas componentes pode ser crítico em diferentes tarefas. Para melhor compreensão desses fatos, esta seção trata dessas componentes.

As componentes mais amplamente descritas na literatura são a tendência, a sazonalidade e o ruído. A tendência é uma componente que representa a direção dos dados ao longo do tempo. Ela indica o comportamento da série a médio ou longo prazo, indicando se os valores observados estão em ascensão, diminuição ou permanecem estáveis. A tendência pode ser linear ou não e pode ser global, que ocorre durante toda a observação do fenômeno, ou local, que representa a direção do movimento das observações em uma subsequência.

A Figura 2.4 mostra um exemplo de quatro caminhadas aleatórias com tendências diferentes.

A sazonalidade se refere a flutuações regulares que ocorrem em intervalos fixos de tempo. Pode ser vista como um comportamento padrão que ocorre em um determinado intervalo de um período. Por exemplo, a série temporal de volume de vendas de uma de brinquedos deve possuir um pico muito evidente próximo ao dia das crianças, seguido de uma queda e outro pico próximo ao Natal. Esse é um comportamento que se repete a cada ano, portanto é um comportamento sazonal.

Também é possível encontrar na literatura a descrição de outra componente, que possui relações com a sazonalidade, conhecida como ciclo. Assim como a sazonalidade, o ciclo também está relacionado a padrões de variação. Porém, esta componente não

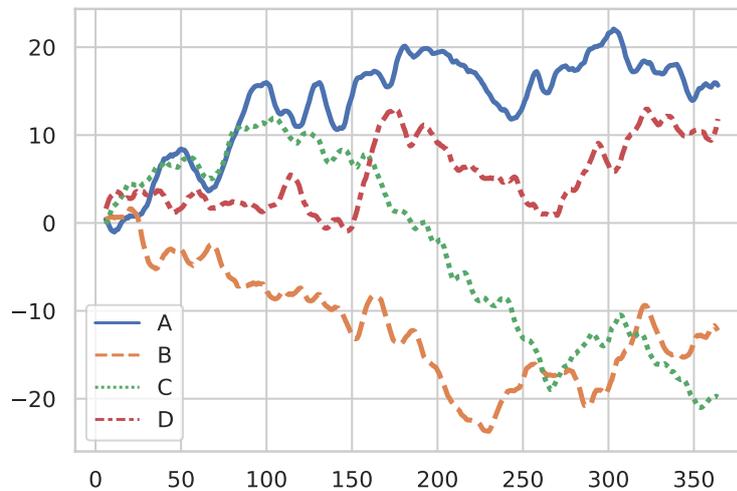


Figura 2.4. Exemplo de quatro séries temporais com tendências distintas. A série A possui uma clara tendência crescente. A série B também possui uma elevação global, porém com tendências locais de estabilidade (como nas primeiras 150 observações) e decrescente (aproximadamente entre as observações 175 e 275). As séries C e D possuem em tendência global decrescente. Porém, é possível observar uma tendência local de queda nas primeiras 100 observações da série C.

considera os padrões sazonais, mas aqueles que ocorrem em intervalos irregulares e, geralmente, que abrangem períodos mais longos. São, portanto, interessantes para o estudo do comportamento da série a médio/longo prazo.

Além das componentes mencionadas anteriormente, as séries temporais também podem conter variações irregulares ou aleatórias que não podem ser atribuídas a tendência, sazonalidade ou ciclo. Para essas flutuações, comumente atribui-se o termo “ruído”. Variações causadas por fatores imprevisíveis e imprecisões de medida são os principais causadores de irregularidade. Porém, as variações não observadas na tendência e sazonalidade também podem representar informação relevante, pois podem ter sido causadas por perturbações no fenômeno observado.

Uma série temporal pode ser, então, constituída por uma combinação dessas componentes. Especificamente, essa combinação pode ser aditiva ou multiplicativa. Formalmente, a decomposição aditiva representa a série temporal pela soma das componentes, ou seja, $S = S_{tend} + S_{sazon} + S_{irreg}$, em que S_{tend} , S_{sazon} e S_{irreg} são os valores de tendência, sazonalidade e variações irregulares associados a cada observação da série, respectivamente. De forma similar, a decomposição multiplicativa considera que as componentes devem ser multiplicadas para produzir a série temporal associada, ou seja, $S = S_{tend} * S_{sazon} * S_{irreg}$.

A decomposição das séries temporais em suas componentes individuais permite analisar separadamente cada aspecto do fenômeno em estudo. Além de facilitar a compreensão do fenômeno, o correto tratamento das componentes, como a remoção de componentes indesejadas, pode melhorar significativamente a qualidade das análises e previsões realizadas a partir de séries temporais. Devido à sua importância, este capítulo apresenta

uma forma prática de realizar essa decomposição como uma etapa do pré-processamento de séries temporais, na Seção 2.3.

2.2.4. Domínio da frequência

Outra forma de se representar uma série temporal é por meio de suas componentes de frequência. A intuição por trás dessa representação vem da Transformada de Fourier, que expressa funções em termos de funções de base sinusoidal [Bloomfield 2004].

Uma vez que trabalhamos com um número finito de observações para representar o fenômeno observado ao longo do tempo, pode-se utilizar a Transformada Discreta de Fourier para se representar a série, originalmente no domínio do tempo, para o domínio de frequências. Usualmente, essa operação é realizada por meio do algoritmo da Transformada Rápida de Fourier. Como resultado, cada componente é caracterizada por sua frequência e amplitude.

A Figura 2.5 ilustra a fotopleitismografia apresentada na Figura 2.3 junto à sua representação no domínio de frequências.

A amplitude de cada componente representa a contribuição relativa dessa frequência específica na série temporal. Valores maiores de amplitude indicam uma maior influência daquela frequência na série. Dessa forma, é possível identificar quais frequências têm um papel mais significativo na série temporal. Essa análise pode levar à observância de determinados padrões ou fenômenos representados na série. Por exemplo, a análise das componentes de frequência de um eletrocardiograma pode evidenciar padrões de ritmos cardíacos, auxiliando na identificação de batimentos cardíacos anormais.

No entanto, é importante ressaltar que a Transformada de Fourier pressupõe que a série temporal seja estacionária e linear. Caso essas suposições não sejam atendidas, pode ser necessário realizar a análise no domínio de tempo-frequência, por meio da Transformada de Fourier de Tempo Curto e suas variantes [Durak and Arikan 2003].

Em alguns casos, as séries temporais podem não atender a essas suposições, e técnicas mais avançadas, como a análise espectral de tempo-frequência, podem ser necessárias.

2.2.5. Aprendizado de Máquina Supervisionado

Aprendizado de Máquina (AM) é um subcampo da Inteligência Artificial (IA) no qual algoritmos apresentam a capacidade de aprender modelos para lidar com uma determinada tarefa a partir da experiência representada por observações anteriores do fenômeno estudado, ou seja, com um conjunto de dados relacionado ao problema a ser resolvido [Mitchell 1997]. Nesse contexto, os principais tipos de aprendizado são o supervisionado, não-supervisionado e por reforço [Faceli et al. 2020].

Este capítulo é voltado exclusivamente para o AM supervisionado. Nesse tipo de aprendizado, considera-se que cada dado possua um atributo alvo, ou variável dependente, a ser predito. A partir de um conjunto de dados rotulados, um algoritmo de AM supervisionado deve induzir um modelo capaz de generalizar o conhecimento descrito pelos dados a fim de prever valores para os atributos alvo de dados ainda não conhecidos. Em

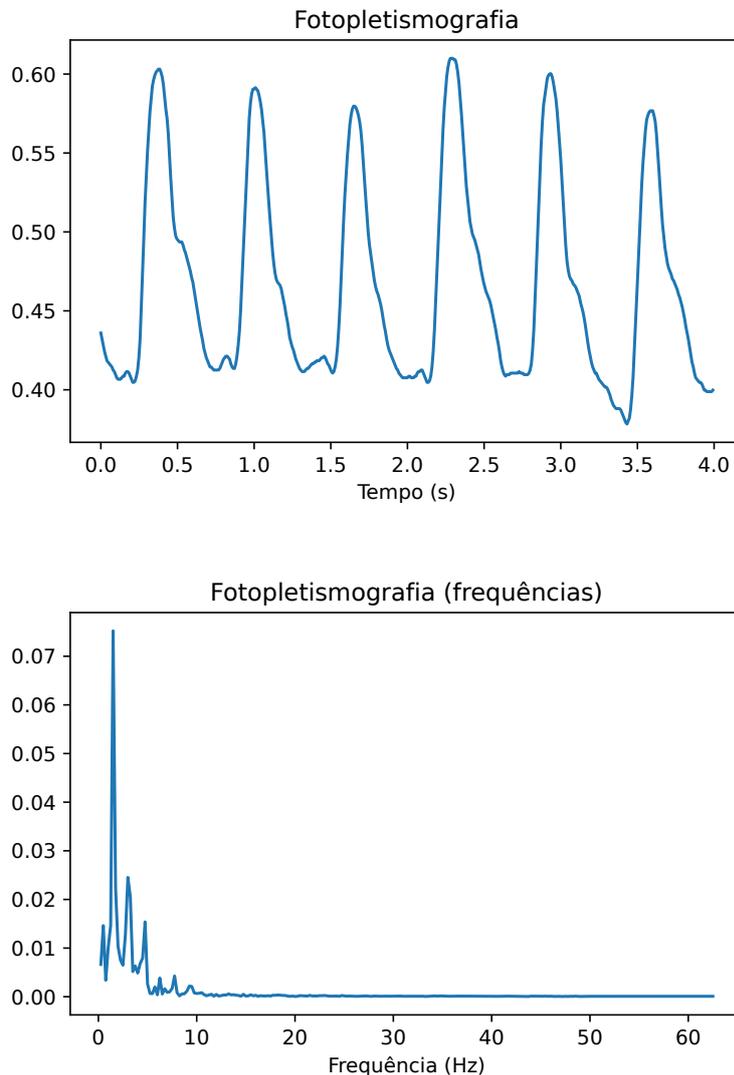


Figura 2.5. Fotoplethysmografia coletada a 125 observações por segundo e sua representação no domínio de frequências.

outras palavras, quando uma nova observação do mesmo fenômeno é feita, esse modelo deve estimar um valor para a variável dependente de tal observação.

Considere um conjunto de dados $X = x_1, x_2, x_3, \dots, x_n$, $n \in \mathbb{N}^*$, em que cada elemento x_i é chamado exemplo. Especificamente, $x_i = (S_i, a_i)$, $i \in (1, 2, 3, \dots, n)$ é um par ordenado contendo as variáveis que descrevem o evento observado S_i e um atributo alvo a_i associado a ele. Neste caso, o conjunto de dados X contém n exemplos.

Quando o atributo alvo a_i contém um valor discreto, podemos chamá-lo de rótulo ou classe. A partir dessa informação, podemos definir a tarefa de classificação como aquela cujo objetivo é obter um modelo tal que, quando uma nova observação é realizada, seja capaz de atribuir corretamente um rótulo a esse novo dado.

Um exemplo de classificação no contexto de séries temporais é a tarefa de reconhecimento de atividades. Nessa tarefa, uma série temporal multidimensional pode ser coletada, por exemplo, por meio do acelerômetro de um celular [Kwapisz et al. 2011] ou outras medidas de inércia de um *smartwatch*, ou outro dispositivo eletrônico vestível. Nesse caso, o conjunto de rótulos a se atribuir para a série temporal observada poderia ser $R = \{ 'correndo', 'caminhando', 'nadando', 'repousando', \dots \}$. Dessa maneira, um algoritmo de classificação deve aprender um modelo a partir séries temporais coletadas do acelerômetro de um celular tal que, para uma nova série temporal coletada, seja capaz de atribuir um valor de R ao atributo alvo a_i .

Caso o conjunto de valores que podem ser conferidos ao atributo alvo seja contínuo, a tarefa de se estimar um valor para a_i é chamada regressão. No caso de séries temporais, utiliza-se o termo “regressão extrínseca”, para não se confundir a tarefa com a atividade de previsão de valores futuros (Seção 2.5.3). Seguindo o exemplo do reconhecimento de atividades, o valor estimado pelo modelo pode ser uma estimativa das calorias gastas durante a atividade observada.

Uma vez que um modelo é treinado, ele é utilizado para prever o valor do atributo alvo para novas observações. Uma forma de avaliar a qualidade do modelo é utilizando um conjunto de dados $Y = \{y_1, y_2, y_3, \dots, y_m\}$, disjunto de X . Além disso, cada instância y_i , $i \in (1, 2, 3, \dots, m)$ é definida pelo seu conjunto de séries temporais, mas o valor de seu atributo alvo não é apresentado ao modelo. Ao final, os valores dos atributos alvo observados (omitidos ao modelo) são comparados com aqueles estimados pelos algoritmos de AM. Quanto mais próximos esses valores, melhor a qualidade do modelo.

A etapa de indução de um modelo a partir do conjunto de dados X é denominada fase de treinamento. Por sua vez, a avaliação a partir do conjunto Y é conhecida como fase de teste ou avaliação.

2.3. Pré-processamento e extração de características

Usualmente, a primeira etapa para se utilizar o Aprendizado de Máquina em séries temporais é a análise exploratória e o pré-processamento dos dados. A análise exploratória permitirá, entre outras coisas, encontrar potenciais problemas nos dados que devem ser tratados para um melhor desempenho na tarefa a ser realizada. Além disso, há muitas abordagens que utilizam a extração de características das séries temporais tanto para exploração quanto para a representação das séries para serem utilizadas como entrada em algoritmos de Aprendizado de Máquina desenvolvidos para dados estruturados.

Nesse contexto, esta seção aborda alguns conceitos importantes de pré-processamento e extração de características de séries temporais.

2.3.1. Remoção de tendência

Quando lidamos com séries temporais na área da Saúde, diversas características indesejadas podem aparecer nos dados. Algumas dessas características podem ser observadas em termos das componentes discutidas na Seção 2.2.3. Por exemplo, a Figura 2.6 mostra uma série temporal de fotopletismografia baseada em *smartphone* [Silva et al. 2023].

Esse dado pode ser sensível a pequenas variações da luz externa, por exemplo, causando uma tendência global decrescente e um artefato (queda brusca) próximo ao final do sinal.

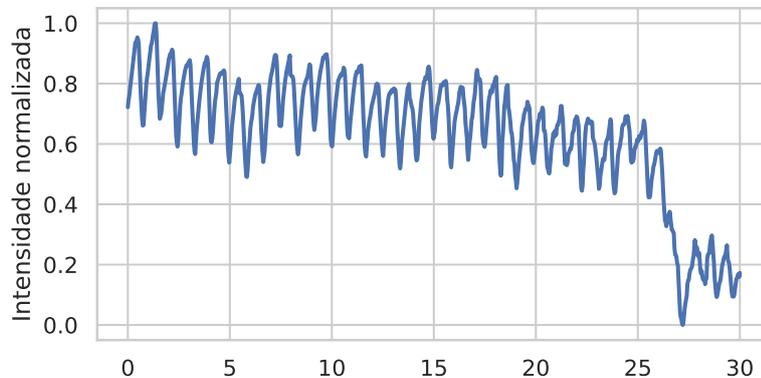


Figura 2.6. Série temporal representando uma fotopletismografia de 30 segundos obtida por *smartphone*.

Para demonstrar a decomposição de séries na prática, podemos aplicar a decomposição sazonal da biblioteca `statsmodel` na série temporal apresentada na Figura 2.6, conforme exibido pelo Código-Fonte 2.1². Nesse caso, consideramos a decomposição aditiva e o período, de acordo com observação do comportamento, um período de 24 unidades. Em outras palavras, consideramos que o ciclo de subida e descida da intensidade da luz dura 24 observações. Uma vez que este dado possui uma amostragem de 30 observações por segundo, esse ciclo corresponde a aproximadamente 0,8 segundos.

Código-Fonte 2.1. Decompor uma série temporal.

```

1 from statsmodels.tsa.seasonal import seasonal_decompose
2
3 import matplotlib.pyplot as plt
4 import numpy as np
5
6 series = np.genfromtxt('data.tsv', delimiter='\t')
7 result = seasonal_decompose(series,
8                             model='additive',
9                             period=24)
10
11 plt.figure(figsize=[6,9])
12 result.plot()
13 plt.show()

```

O resultado dessa operação é exibido na Figura 2.7.

Seguindo-se esse exemplo, é possível verificar a série temporal resultante da remoção da componente de tendência. A Figura 2.8 mostra o resultado da soma das componentes de sazonalidade e ruído, resultante do Código-Fonte 2.2.

²Para melhor entendimento da leitura dos dados, recomendamos o leitor se direcionar à Seção 2.5.1

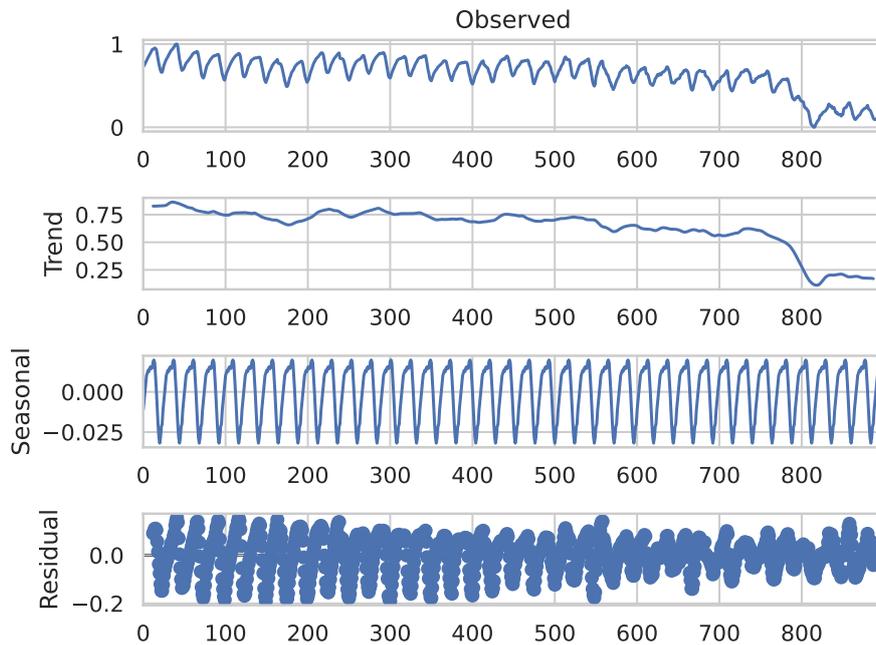


Figura 2.7. Resultado da decomposição aditiva da série exibida na Figura 2.6 (topo) em tendência, sazonalidade e ruído (do segundo quadro em diante, de cima para baixo, respectivamente).

Código-Fonte 2.2. Exibir a série resultante da remoção da componente de tendência.

```

1 import seaborn as sns
2 sns.set_theme(style='whitegrid')
3
4 plt.figure(figsize=[6,3])
5 sns.lineplot((result.seasonal + result.resid), linewidth=2)
6 plt.plot()

```

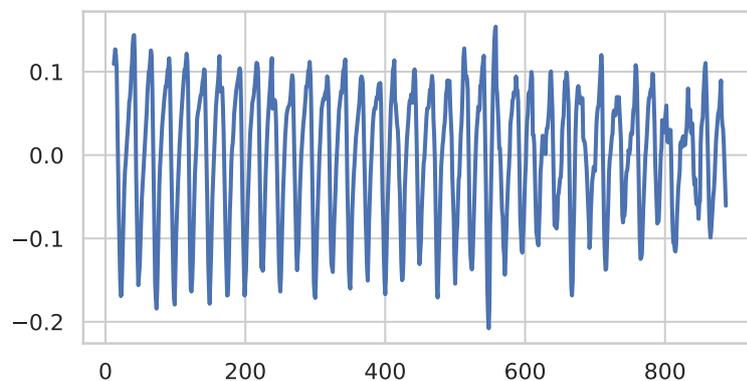


Figura 2.8. Resultado da remoção da componente de tendência.

2.3.2. Interpolação

Além de problemas relacionadas às suas componentes, há outras características indesejadas que podem ser observadas em séries temporais de quaisquer domínios de aplicação. Dois dos mais comuns, que também podem ocorrer no domínio da Saúde, são a amostragem irregular e os valores ausentes. No primeiro caso, a suposição de amostragem uniforme é invalidada. No segundo, alguns algoritmos podem falhar ao fazer previsões. Nos dois casos, é possível utilizar técnicas de interpolação, que é o processo de estimar valores intermediários entre observações com valores conhecidos a fim de preencher lacunas causadas por valores ausentes. Existem várias abordagens de interpolação, variando-se a suposição da complexidade que os valores ausentes podem assumir.

A interpolação linear pressupõe uma relação linear entre os pontos conhecidos adjacentes. Dessa forma, calcula os valores intermediários usando uma combinação linear ponderada entre esses vizinhos de valores conhecidos. A interpolação polinomial generaliza a interpolação linear ao aplicar uma função polinomial para estimar os valores intermediários. Para isso, ajusta-se o polinômio aos pontos conhecidos da série temporal e, então a função é utilizada para estimar os valores ausentes. Por fim, outra técnica de interpolação muito conhecida é a aplicação de *splines*. Assim como a interpolação polinomial, ajusta uma curva aos valores conhecidos para estimar valores para as observações com valores ausentes. Porém, nesse caso, é utilizada uma combinação de polinômios por partes, conhecida como *spline*.

Para realizar a interpolação, é comum a utilização da biblioteca `pandas`, bastante conhecida para a leitura e manipulação de dados. No Código-Fonte 2.3, são removidas 300 observações (um terço) da série temporal aleatoriamente. A seguir, são exibidas as séries com tais valores ausentes e o resultado da interpolação linear. O gráfico resultante é exibido na Figura 2.9.

Código-Fonte 2.3. Remover observações e interpolar valores para substituí-los.

```

1 import random
2 import pandas as pd
3
4 random.seed(42)
5 to_remove = random.sample(range(series.size), 300)
6 series[to_remove] = np.nan
7
8 fig, (ax1, ax2) = plt.subplots(2, 1, figsize=[6,8])
9
10 ax1.plot(series)
11 ax1.set_title('Série com valores ausentes')
12
13 ax2.plot(pd.DataFrame(series).interpolate(method='linear'))
14 ax2.set_title('Série com interpolação linear')
15
16 plt.show()

```

No caso de haver uma frequência de amostragem irregular, é possível utilizar interpolação para realocar os pontos observados, a partir deles, interpolar a série temporal

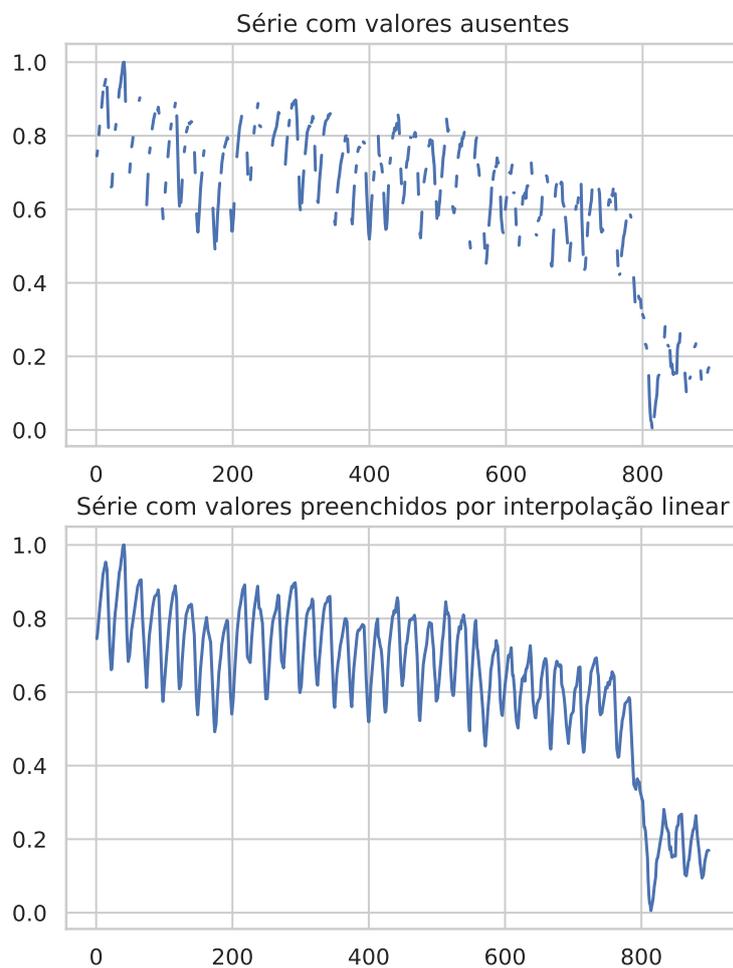


Figura 2.9. Série temporal com valores ausentes e o resultado da interpolação linear.

nos pontos em que o valor está ausente. Essa operação permite uma análise mais consistente e facilita a aplicação de técnicas específicas para séries temporais, em especial, de Aprendizado de Máquina.

2.3.3. Filtragem

Além das flutuações aleatórias que podem ser observadas na decomposição de séries temporais, os sinais obtidos a partir da observação de um fenômeno também podem sofrer ruídos que não são inerentes ao que está sendo estudado. Um exemplo disso são os ruídos relacionados a problemas de medição. Geralmente, esse tipo de ruído ocorre devido a limitações do *hardware* utilizado para a coleta dos dados.

Seguindo o exemplo do uso de acelerômetros para monitorar pacientes portadores da doença de Parkinson, apresentado na Seção 2.2.2, deve-se considerar que o acelerôme-

tro pode possuir uma imprecisão que o faz registrar um ruído de alta frequência. Assim, a série temporal coletada não representa apenas a informação motora do paciente de forma clara, mas também adiciona uma variação que não adiciona qualquer informação para a aplicação.

Esse tipo de problema é muito comum em diversas aplicações. Para resolvê-lo, utilizamos técnicas de filtragem. A filtragem é o processo utilizado para remover ou atenuar componentes indesejáveis das séries temporais, preservando as características relevantes do fenômeno analisado. Esse conjunto de técnicas é amplamente utilizado para reduzir ruído, destacar padrões e facilitar a interpretação dos dados.

Formalmente, a filtragem em séries temporais consiste em aplicar um filtro a uma série temporal $S = (s_1, s_2, \dots, s_n)$, visando obter uma nova série temporal filtrada $S_f = (s_{f_1}, s_{f_2}, \dots, s_{f_n})$. O filtro utilizado pode ser representado por uma função matemática ou algoritmo que opera sobre os valores da série temporal.

Uma das técnicas mais comuns de filtragem é o filtro de passa-banda (ou passa-faixa). Esse filtro define uma faixa de frequências desejadas, o que é usualmente definido por conhecimento de domínio e pode variar significativamente entre uma aplicação e outra. A partir disso, o filtro elimina ou atenua as componentes fora da faixa definida. O passa-banda pode ser visto como a combinação dos filtros de passa-baixa, que elimina componentes de alta frequência, e de passa-alta, que elimina componentes de baixa frequência.

Outro tipo de filtro muito comum é o de médias móveis. Esse filtro substitui o valor de um ponto pelo valor médio de um subconjunto de pontos temporalmente vizinhos a ele. O filtro de médias móveis pode suavizar flutuações de curto prazo e remover ruídos de alta frequência. Um exemplo claro de médias móveis é a sua utilização na análise do número de casos de uma determinada doença, como foi comum para a COVID-19. O padrão do número de casos sofria uma variação muito significativa conforme o dia da semana. Por isso, optou-se pela utilização da média móvel de sete dias, o que remove a flutuação diária e apresentava uma informação mais clara sobre a evolução da pandemia.

Na linguagem Python, a biblioteca mais comumente utilizada para se calcular a média móvel de séries temporais é a biblioteca `pandas`. Para visualizar o efeito desse filtro, vamos primeiramente adicionar ruído nas frequências entre 40 Hz e 62 Hz do eletrocardiograma exibido na Figura 2.3. A Figura 2.10 mostra a influência desse ruído nos domínios de tempo e de frequência do sinal.

O Código-Fonte 2.4 ilustra como é simples realizar a filtragem por média móvel no sinal por meio da biblioteca.

Código-Fonte 2.4. Utilizar o filtro de médias móveis de tamanho 3.

```
1 new_ecg = pd.DataFrame(ecg_noisy).rolling(3).mean()
```

O resultado dessa operação é apresentado pela Figura 2.11. É possível notar que o sinal se parece muito mais com o original do que o sinal ruidoso se parecia. No domínio das frequências, nota-se que as magnitudes das frequências acima dos 40Hz foi bastante reduzido. No entanto, também se nota uma atenuação do vale de curta duração correspondente a onda Q do complexo QRS, o que pode prejudicar a interpretação do

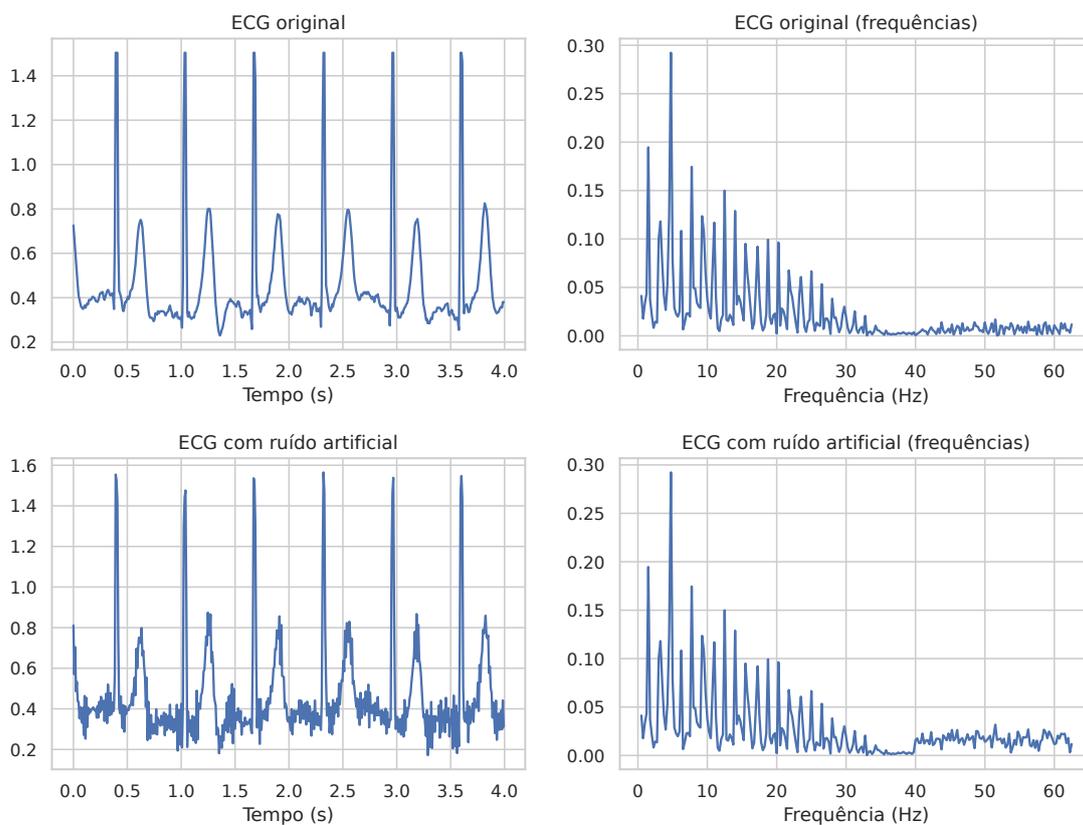


Figura 2.10. Série temporal (original acima) com ruído artificialmente inserido (abaixo).

dado [Kashani and Barold 2005]. Por isso, ao mesmo tempo que a filtragem de séries temporais pode ser extremamente relevante para se obter sucesso na tarefa realizada, ela deve ser executada com cautela.

2.3.4. Extração de características

Uma das principais tarefas a ser desenvolvidas em análise de séries temporais é a extração de características. Formalmente, a extração de características em séries temporais consiste em mapear uma série temporal $S = (s_1, s_2, \dots, s_n)$ em um vetor de características $\mathbf{X} = (x_1, x_2, \dots, x_m)$, onde m é o número de características extraídas. Cada característica x_i representa uma medida específica ou propriedade derivada dos dados.

Descrever a série temporal por meio de atributos significativos pode fornecer informação relevante para a interpretação do fenômeno observado. Por exemplo, atributos interpretáveis podem ser utilizados em etapas de análise exploratória, escolha de algoritmos para diferentes tarefas e até mesmo entrada para algoritmos de Aprendizado de Máquina projetados para lidar com dados estruturados [Ruiz et al. 2020, Gay et al. 2021].

Devido à sua importância, foram construídas diversas ferramentas para a extração de séries temporais. A maioria das bibliotecas de extração de características para séries temporais lançadas nos últimos anos, como a `tsfel` [Barandas et al. 2020] e a

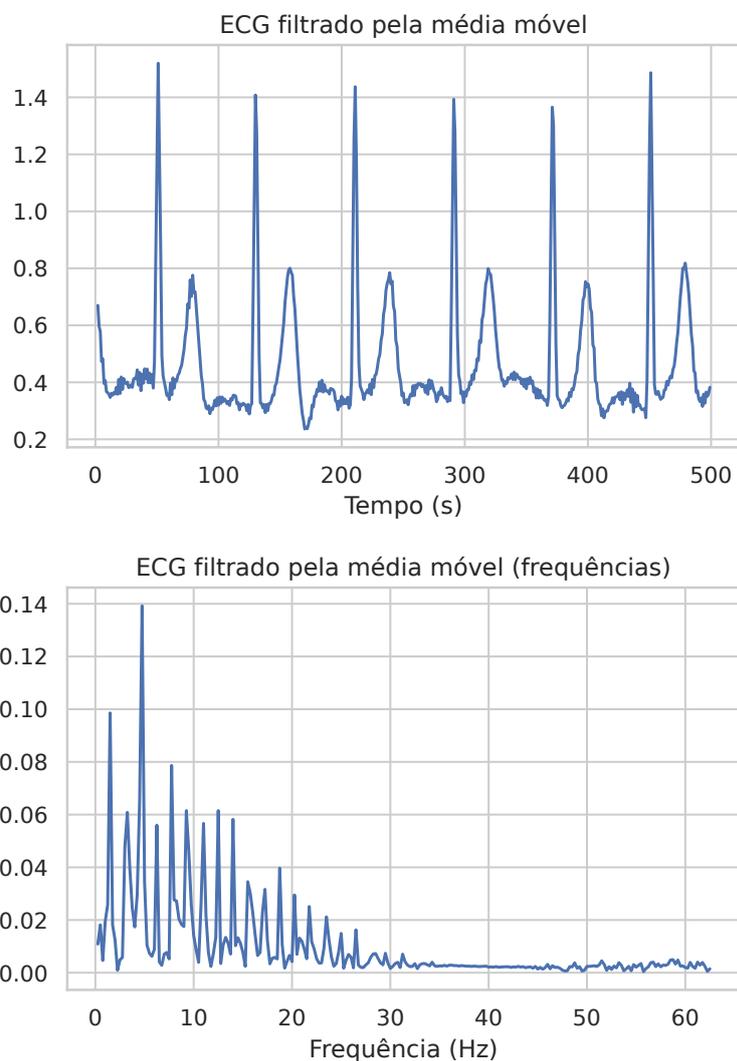


Figura 2.11. ECG filtrado por média móvel de tamanho 3 e seu efeito no domínio de frequências.

`tsfresh` [Christ et al. 2018], foram desenvolvidas para a linguagem Python. Há ferramentas em outras linguagens, como a `hctsa` [Fulcher and Jones 2017], para Matlab.

Além disso, diferentes ferramentas de Aprendizado de Máquina para séries temporais possuem módulos específicos para a extração de características, visto que diversos algoritmos usam essa tarefa como uma das etapas de seu *pipeline*. Porém, como ocorre com as bibliotecas `aeon` e `tsai`, a extração de características é feita, parcial ou completamente, pela aplicação da biblioteca `tsfresh`.

Geralmente, as características extraídas por essas ferramentas estão em categorizadas conforme as transformações realizadas ou domínio em que são extraídas. Por exemplo, a `tsfresh` possui 63 métodos de caracterização distintos, sendo que alguns extraem um conjunto de características. No total, a biblioteca extrai, por padrão, 794 ca-

racterísticas de cada série temporal. Essas características podem ser extraídas no domínio do tempo, da frequência ou de tempo-frequência.

A Figura 2.12 ilustra algumas das características que a `tsfresh` calcula no domínio do tempo. Nela, são ilustradas as características de média, mediana, máximo, mínimo e número de picos. Além dessas, diversas outras estatísticas descritivas, como curtose das suas observações e contagem de pontos acima da média são extraídas nesse domínio.

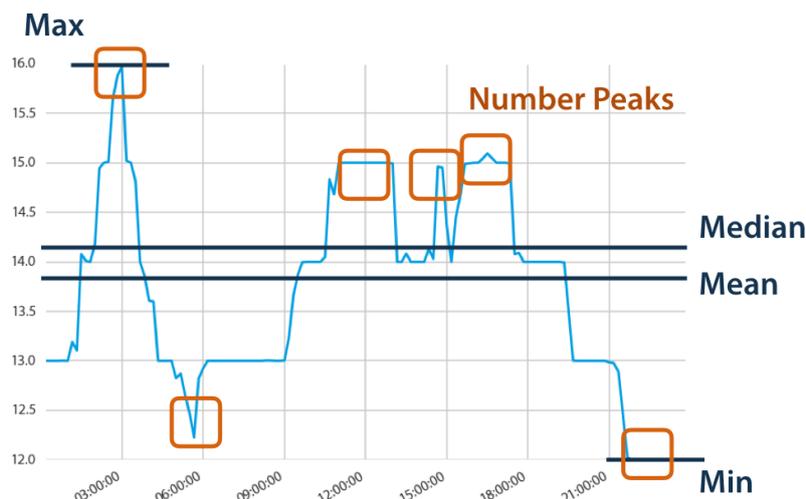


Figura 2.12. Esquema ilustrativo de algumas características que podem ser extraídas da série temporal. Fonte: Documentação da biblioteca `tsfresh` (<https://tsfresh.readthedocs.io/>)

Algumas características possuem uma interpretação relativamente simples de seu significado em relação ao comportamento da série temporal. Por exemplo, para dados oriundos da fotopleletismografia de dois pacientes com a maior e menor frequência cardíaca do conjunto de dados BIDMCHR (ver Figura 2.18), é possível notar diferenças significativas em alguns dos valores obtidos. A complexidade estimada do sinal, por exemplo, é diretamente proporcional à variação da série temporal. Intuitivamente, quanto mais picos e vales uma série possuir, maior será sua complexidade. No exemplo da estimativa de frequência cardíaca, a complexidade estimada a partir da fotopleletismografia do paciente com frequência cardíaca de 60,09 bpm é de 4,05. Para o paciente com frequência cardíaca de 125,28 bpm, a complexidade estimada é 8,75.

Há diferentes conjuntos padrão de características que a `tsfresh` utiliza para representar as séries por meio de atributos. Por exemplo, a ferramenta pode extrair todas as características disponíveis, apenas aquelas marcadas como “eficientes”, apenas as características extraídas no domínio do tempo, entre outros. Além disso, é possível definir manualmente um conjunto de características a serem calculadas.

Essas ferramentas, incluindo o `tsfresh`, são capazes de extrair características de séries uni ou multivariadas. No caso de séries multivariadas, é possível extrair subconjuntos diferentes de características de cada variável. Por exemplo, um especialista pode entender que um determinado subconjunto de atributos é mais relevante para representar um eletrocardiograma e outro subconjunto, potencialmente com intersecção com o primeiro, seja melhor para fotopleletismografia.

É importante notar que todas essas características são não-supervisionadas. Em outras palavras, não é necessária a informação de rótulo para estimá-las. Esse fato possui duas grandes vantagens. Primeiro, não depender de um atributo-alvo para realizar a extração de características costuma levar a técnicas mais computacionalmente eficientes. Além disso, a não dependência de um atributo alvo leva a características que generalizam melhor a caracterização das séries, melhorando a interpretação de seus significados mesmo em domínios e conjuntos de dados completamente diferentes.

A ferramenta `hctsa` (acrônimo para *Highly Comparative Time Series Analysis*) [Fulcher and Jones 2017] possui um conjunto consideravelmente maior de características que a `tsfresh`. Ela pode realizar a extração de mais de 7500 características. Enquanto, por um lado, esse número seja vantajoso no sentido de descrever a série temporal em abrangência e detalhe, isso torna a extração muito custosa. Além disso, mesmo os algoritmos aplicados sobre esses atributos podem sofrer tanto com o custo computacional quanto com a maldição da dimensionalidade [Köppen 2000].

Porém, muitas dessas características são muito correlacionadas e outras possuem pouco poder discriminativo. Quando elas são aplicadas em problemas, digamos, de classificação, muitas características acabam possuindo pouca relevância para a tarefa.

Foi pensando nessa problemática que foi criado o conjunto de características canônicas para séries temporais (`catch22`, do inglês *CAnonical Time-series CHaracteristics*) [Lubba et al. 2019]. Por meio de um processo supervisionado, foram selecionadas 22 atributos que são bem discriminativos transversalmente em muitos domínios de aplicação e sejam pouco redundantes entre si.

Nesse contexto, alguns dos algoritmos que alcançam os melhores resultados nas tarefas de classificação e regressão extrínseca de séries temporais se baseiam na extração de características, em especial das bibliotecas mais exploradas nesta seção: da `tsfresh` ou `catch22` [Middlehurst and Bagnall 2022, Guijo-Rubio et al. 2023].

2.4. Algoritmos e Técnicas de Classificação e Regressão Extrínseca

As duas tarefas abordadas neste capítulo, classificação e regressão extrínseca, possuem uma relação muito próxima. Além de ambas serem tarefas de Aprendizado de Máquina supervisionado, compartilham as características dos dados, como a dependência temporal entre as observações. Conseqüentemente, muitas das premissas adotadas para a proposta de algoritmos de classificação valem para algoritmos de regressão extrínseca (e vice-versa).

Nesta seção, serão abordadas as diferentes categorias de algoritmos existentes na literatura para classificação e regressão extrínseca de séries temporais. Serão discutidas quatro principais categorias de algoritmos: baseados em distância; baseados em intervalos; baseados em dicionários; aprendizado profundo; e comitês.

2.4.1. Algoritmos Baseados em Distância

Os algoritmos de Aprendizado de Máquina para classificação e regressão baseados em distâncias operam comparando a similaridade entre as instâncias, neste caso as séries temporais, por meio de medidas de distância, tais como a distância Euclidiana, a distância

Manhattan ou *Dynamic Time Warping* (DTW). Neste caso, um rótulo é atribuído a uma instância baseando-se na similaridade com outras instâncias já rotuladas.

Nesta categoria, identificar e entender a medida de similaridade mais adequada para o problema é um fator crucial para obter um bom desempenho na tarefa. Desta forma, otimizar esse parâmetro é uma tarefa essencial, caso contrário a medida utilizada não irá capturar adequadamente a similaridade existente entre os dados, tornando o modelo ineficaz para a tarefa.

Uma primeira ideia, mais direta e amplamente utilizada, para comparar a similaridade entre duas séries é calcular a distância euclidiana entre os seus valores em cada instante. Contudo, esse tipo de medida não considera pequenas variações no eixo do tempo da série. Por exemplo, basta que uma série receba um *shift* de alguns pontos para que se torne muito dissimilar a si mesma, mesmo capturando, em essência, o mesmo fenômeno.

Por isso, foram criadas diversas medidas de distância entre séries que consideram essas pequenas distorções no eixo do tempo. Exemplos populares são a *Dynamic Time Warping* (DTW), *Derivative Dynamic Time Warping* (DDTW) e *Longest Common Subsequence* (LCSS). A Figura 2.13 mostra como a DTW considera o aspecto temporal das séries: ela “distorce” o pareamento de pontos para reduzir o impacto de deslocamentos temporais.

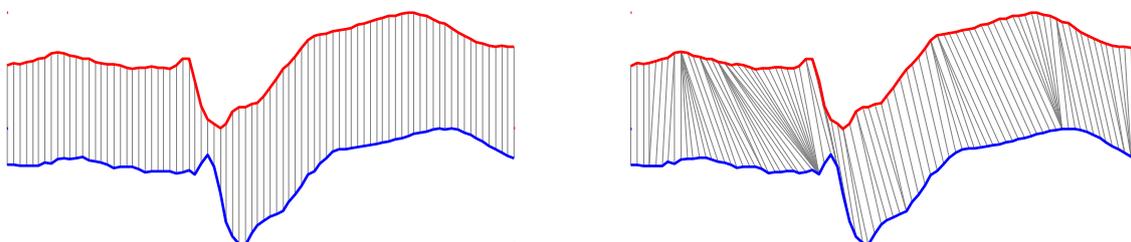


Figura 2.13. Alinhamento de pontos de séries temporais na distância euclidiana (esquerda) e na DTW (direita) [Silva 2017].

Para construir um modelo que lance mão de medidas de distância/similaridade, pode-se utilizar o algoritmo *k*-Vizinhos Mais Próximos, no qual a cada instância é atribuída a média dos atributos-alvo das *k* instâncias rotuladas mais similares, no caso de regressão, ou a classe mais frequente dentre as *k* instâncias rotuladas mais similares, no caso de classificação.

Outros modelos mais elaborados que utilizam medidas de distância são o *Elastic Ensemble* (EE) [Lines and Bagnall 2015], uma combinação de onze modelos *k*-Vizinhos com diferentes medidas e conjuntos de valores de parâmetros; a *Proximity Forest* (PF) [Lucas et al. 2019], que constrói árvores de decisão cujo critério de decisão é a distância (dentre as onze medidas usadas pelo EE) a exemplares escolhidos aleatoriamente; e a *Proximity Forest 2* (PF2) [Herrmann et al. 2023], que simplifica e reduz as possíveis medidas de distância da PF.

2.4.2. Algoritmos Baseados em Intervalos

Na Seção 2.3.4, foram descritas maneiras de extrair características de séries temporais. Contudo, alguns algoritmos trabalham com a extração de características de intervalos delimitados das séries, em vez de sua totalidade. Em geral, esses algoritmos constroem combinações de modelos nas quais cada modelo se ajusta a um ou mais intervalos de um conjunto de séries.

Um dos mais simples modelos baseados em intervalos é a *Time Series Forest* (TSF) [Deng et al. 2013]. A TSF constrói uma árvore de decisão para cada intervalo escolhido aleatoriamente, sendo que a média, o desvio padrão e o *slope* de cada intervalo são usados como as características de entrada de cada árvore.

O *Random Interval Spectral Ensemble* (RISE) [Lines et al. 2018] funciona de forma muito similar à TSF. Porém, as características extraídas de cada intervalo vêm do domínio da frequência, e não do tempo, como o *Power Spectrum* (PS) e a *Autocorrelation Function* (ACF).

Por fim, os mais recentes avanços em algoritmos baseados em intervalos são a *Canonical Interval Forest* (CIF) [Middlehurst et al. 2020] e a *Diverse Representation Canonical Interval Forest* (DrCIF) [Middlehurst et al. 2021]. A CIF funciona da mesma forma que a TSF, ou seja, construindo árvores de decisão baseadas em características extraídas de intervalos. Entretanto, são adicionadas às características extraídas na TSF os 22 atributos presentes no *catch22* (descrito na Seção 2.3.4), o que contribui para que o CIF tenha grande poder discriminatório em vários conjuntos de dados. A DrCIF, por sua vez, expande a gama de atributos extraídos ao considerar, para cada instância, a sua primeira derivada e o seu periodograma, além dela própria, como entradas para a extração.

2.4.3. Algoritmos Baseados em Dicionários

Os algoritmos baseados em dicionário tentam discretizar as séries em sequências de padrões (ou *palavras*), criando, assim, dicionários que representam a frequência observada de cada palavra nessas séries. Os modelos, por fim, discriminam as classes ou valores-alvo de um conjunto de séries ao comparar os dicionários gerados a partir de cada uma.

Um exemplo desse tipo de algoritmo é o *Bag of SFA Symbols* (BOSS) [Schäfer 2015], que consiste em uma sequência de diversas etapas. Primeiro, são extraídas janelas deslizantes das séries, isto é, são considerados trechos de tamanho fixo w que se movem uma observação à frente a cada iteração. Cada janela, então, passa por um processo chamado *Symbolic Fourier Approximation* (SFA) [Schäfer and Höggqvist 2012], no qual seus l primeiros coeficientes espectrais (obtidos da sua Transformada Discreta de Fourier) são discretizados em c compartimentos (ou *letras*) de forma que cada compartimento contenha quase o mesmo número de instâncias.

Após a SFA de cada janela, cada série se torna uma sequência de palavras de l letras, formadas a partir de um alfabeto de tamanho c . Uma redução de redundância é então aplicada a essas sequências, ou seja, em caso de palavras iguais consecutivas, apenas o primeiro caso é considerado. O número de ocorrências de cada palavra é, então, contado em cada sequência, obtendo-se assim um conjunto de histogramas, dicionários ou sacola de palavras (do inglês, *bag of words*).

Por fim, a classificação de instâncias é feita por meio de um algoritmo de 1-Vizinho Mais Próximo, que considera os dicionários obtidos. A medida de distância considerada por ele é definida na Equação 3, chamada de *Distância BOSS* pelos autores originais. Note que, nesta medida, apenas as palavras não ausentes na primeira sacola são consideradas, tornando a distância não comutativa. Uma instância recebe, por fim, a classe da instância rotulada mais próxima.

$$\text{dist}(B_1, B_2) = \sum_{w \in B_1 | B_1(w) > 0} [B_1(w) - B_2(w)]^2 \quad (3)$$

O processo de transformação em histogramas realizado pelo BOSS é ilustrado na Figura 2.14.

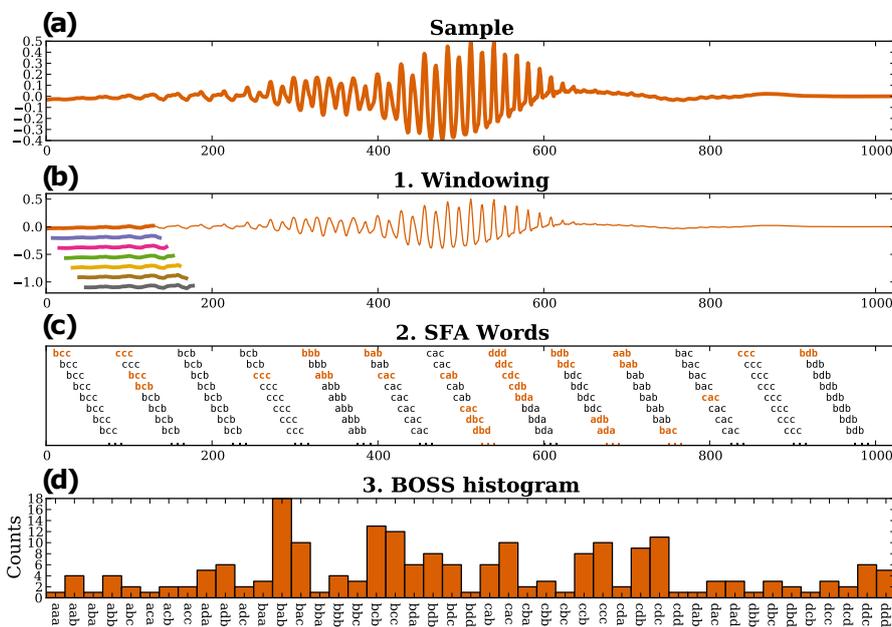


Figura 2.14. Ilustração das etapas do algoritmo BOSS utilizando-se palavras de tamanho 3 e alfabeto de tamanho 4. As palavras em preto são desconsideradas devido à redução de numerosidade [Schäfer 2015].

2.4.4. Aprendizado Profundo

O aprendizado profundo, ou em inglês *deep learning*, têm recentemente recebido grande atenção na literatura. Essa categoria de algoritmos de Aprendizado de Máquina tem ultrapassado o desempenho de outros algoritmos mais clássicos em diversas tarefas. Nesta seção, serão explicados os conceitos básicos para o entendimento em alto nível do aprendizado profundo e de redes neurais.

Esta categoria de algoritmos inspirou-se na estrutura de funcionamento do cérebro humano, englobando técnicas de treinamento de redes neurais para realizar tarefas complexas envolvendo processamento massivo de dados. Essas redes neurais consistem em camadas de funções conectadas que, assim como neurônios naturais, trocam informação entre si, mas processam seu sinal de entrada individualmente. Ou seja, este conceito pode ser entendido superficialmente como um modelo simplificado do cérebro humano.

Assim como o cérebro trabalha com as conexões entre os neurônios para desempenhar tarefas complexas, as redes neurais (artificiais) simulam essas conexões para capturar padrões nos dados por meio de pesos atribuídos às suas entradas, assim como as sinapses do cérebro humano.

Na Figura 2.15, é possível observar uma rede neural de exemplo, na qual uma série temporal de eletrocardiografia é tomada como entrada. Nessa representação, os neurônios ativados estão na cor vermelha. Na saída, é possível observar que o neurônio ativado com maior valor é o que indica a classe normal, ou seja, o ECG de entrada é pertencente a um paciente saudável, sem nenhuma anomalia no ritmo cardíaco.

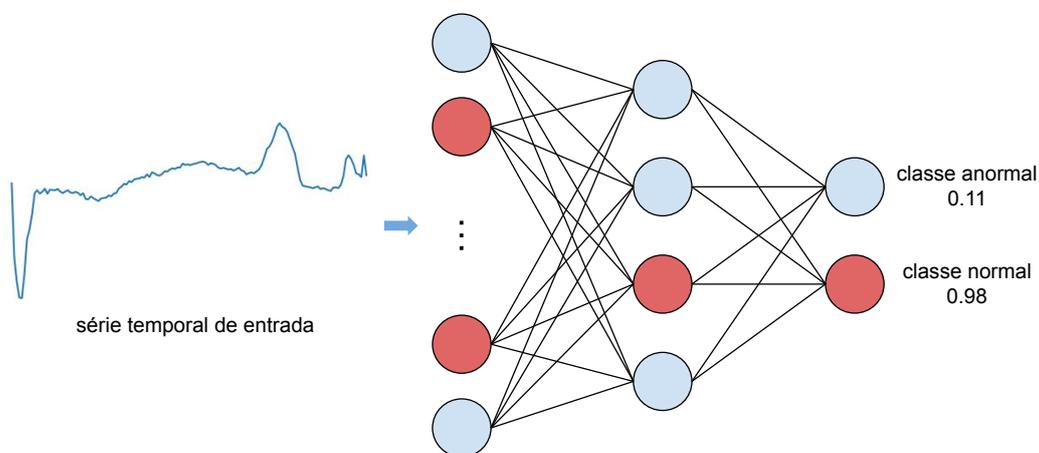


Figura 2.15. Exemplo de uma rede neural artificial na qual a entrada é uma série temporal de um eletrocardiograma e a saída são as classes normal e anormal, que indica uma anomalia.

Para o treinamento destas redes, faz-se necessária a existência de um conjunto de dados rotulados. Desta forma, a rede irá aprender as relações importantes nos dados para que o rótulo seja predito. Sejam essas relações importantes para definir um dado como pertencente a uma classe, como uma anomalia em batimento cardíaco pode indicar uma doença, ou uma relação em uma fotopletismografia indicando um valor de saturação do oxigênio, em uma tarefa de regressão extrínseca. Entretanto, é necessário um grande volume de dados para que a rede possa aprender essas relações complexas nos dados, o que pode ser um fator limitante para o uso de redes neurais.

Tratando-se especificamente de redes neurais no domínio de séries temporais, estudos comprovam a competitividade dessas técnicas quando comparadas com métodos do estado da arte, tanto para classificação quanto para regressão extrínseca [Fawaz et al. 2019, Foumani et al. 2023]. Dentre as arquiteturas de redes neurais utilizadas para obter bons desempenhos reportados na literatura, destaca-se o InceptionTime [Fawaz et al. 2020], que demonstrou uma boa capacidade de obter um bom desempenho para séries temporais de variados domínios.

2.4.5. Algoritmos Baseados em Comitês

Com esses e muitos outros algoritmos, a área de Aprendizado de Máquina para séries temporais também se enquadra em um clássico problema do Aprendizado de Máquina: o teorema “não há almoço grátis” [Wolpert 2002]. Como cada algoritmo compreende um viés indutivo diferente, não há um algoritmo que melhor desempenhe em quaisquer conjuntos de dados. Comparações experimentais em larga escala [Bagnall et al. 2017] podem mostrar que um algoritmo A é melhor que B na média dos resultados para os conjuntos de dados utilizados no experimento, mas sempre há uma fração dos conjuntos de dados nos quais B desempenha melhor que A .

Os vieses intrínsecos a modelos de Aprendizado de Máquina podem ser reduzidos combinando-os em modelos coletivos. Ao ajustar diferentes modelos suficientemente variados a um conjunto de dados e rotular uma instância levando-se em conta o voto de cada um, é possível obter um desempenho melhor do que aquele obtido com cada modelo individual. Essa estratégia é comumente referenciada como comitê.

Um dos primeiros modelos de comitê para classificação de séries temporais foi o *Collective of Transformation-Based Ensembles* (COTE, ou Flat-COTE) [Bagnall et al. 2015], que combinou modelos construídos a partir de diversos domínios das séries temporais: tempo, frequência, mudança e *shapelets*. Pouco adiante, foi proposto o *Hierarchical Vote Collective of Transformation-based Ensembles* (HIVE-COTE) [Lines et al. 2018], que melhorou o Flat-COTE ao adicionar uma estrutura hierárquica com votos probabilísticos, dois novos classificadores nos domínios pré-existentes e modelos em dois novos domínios. Os domínios considerados pelo HIVE-COTE são ilustrados por séries simuladas na Figura 2.16.

Por fim, o mais recente HIVE-COTE 2.0 [Middlehurst et al. 2021] substituiu dois classificadores já existentes e adicionou um novo, melhorando ainda mais o desempenho do algoritmo nos conjuntos de dados disponíveis.

2.5. Exemplos de Tarefas de Classificação e Regressão Extrínseca

Esta seção apresenta alguns exemplos práticos de classificação e regressão extrínseca de séries temporais utilizando as ferramentas `tsai` e `aeon`.

2.5.1. Conjunto de Dados

Neste capítulo, foram utilizados diferentes conjuntos de dados nos exemplos exibidos nas seções anteriores. Esses conjuntos de dados foram propostos para as tarefas de classificação e regressão extrínseca. Dois deles serão utilizados para realizar demonstrações práticas. Vale ressaltar que optamos por utilizar conjuntos de séries temporais já segmentadas e pré-processadas. No entanto, recomendamos ao leitor a exploração do repositório de dados PhysioBank³, que possui uma grande quantidade e diversidade de dados, majoritariamente séries temporais, provenientes da área da Saúde.

Para a tarefa de classificação, será utilizado o conjunto de dados ECG5000, disponibilizado no repositório *UCR Time Series Classification Archive* [Dau et al. 2018]. O conjunto é composto por 5000 trechos de eletrocardiogramas, das quais são encontradas

³<https://archive.physionet.org/physiobank/database/>

500 séries no conjunto de treino e 4500 séries no conjunto de teste. Cada série é univariada, possui 140 observações e pode estar rotulada em uma das 5 classes do conjunto. Neste contexto, esse conjunto simula um cenário onde a existência de instâncias rotuladas é limitada se comparado ao número de instâncias não rotuladas.

A Figura 2.17 mostra um exemplo de série para cada uma das classes contidas no conjunto ECG5000.

Os conjuntos utilizados na tarefa de regressão são: BIDMCRR, BIDMCHR e BIDMCSpO2, disponibilizados pelo repositório de dados para regressão extrínseca de séries temporais mantido pela universidade de Monash, a UEA e a UCR [Tan et al. 2021]. Os conjuntos dados BIDMCHR e BIDMCSpO2 dividem-se em 5550 instâncias para o conjunto de treino e 2399 instâncias para o conjunto de teste. Já o BIDMCRR, apesar de possui o mesmo número de instâncias no conjunto de teste, compreende 5471 instâncias para treino.

Todos os conjuntos são compostos por séries temporais multivariadas de 4000 observações. As duas variáveis observadas para esses conjuntos de dados são eletrocardiograma e fotopletismografia. A maior diferença entre esses conjuntos de dados se refere ao atributo alvo, sendo a frequência respiratória (BIDMCRR), a frequência cardíaca (BIDMCHR) e a oxigenação no sangue (BIDMCSpO2).

As Figuras 2.18, 2.19 e 2.20 mostram exemplos de instâncias dos conjuntos BIDMCHR, BIDMCRR e BIDMCSpO2, respectivamente. Cada uma das instâncias está acompanhada de seu valor alvo, sendo que foram selecionados exemplos cujos valores para os atributos-alvo fossem bastante distintos.

2.5.2. Classificação

A classificação de séries temporais é a tarefa de maior foco neste capítulo. A tarefa de classificação pode ser definida, em alto nível, como a indução de um modelo capaz de inferir rótulos para novas observações de um fenômeno. Por exemplo, considere um eletrocardiograma com anotações relativas à apneia. A tarefa de classificação consiste em induzir um modelo a partir desse conjunto de dados anotados e, para um novo paciente, utilizá-lo para inferir, a cada batimento, a presença ou ausência de apneia.

Historicamente, a classificação de séries temporais por meio de algoritmos muito simples se mostrou muito eficiente e eficaz. Como exemplo, o simples algoritmo do vizinho mais próximo foi utilizado com sucesso em uma ampla gama de aplicações. Na última década, inúmeros algoritmos surgiram para essa tarefa. A literatura de classificação de séries temporais tem buscado categorizar esses métodos e entende-se que há ao menos quatro categorias principais de algoritmos: baseados em distância, intervalos, dicionários e aprendizado profundo, já descritos na Seção 2.4. Além disso, há algoritmos que usam ideias contidas em mais de uma dessas categorias, além de algoritmos baseados em comitês de classificadores [Middlehurst et al. 2021].

É importante retomar o fato que há um compromisso entre custo computacional e eficácia de cada algoritmo [Ruiz et al. 2020]. Somado a isso, considera-se o teorema do “não há almoço grátis” [Wolpert 2002]. Sendo assim, é necessário conhecer técnicas baseadas em estimar o desempenho de diferentes algoritmos utilizando o conjunto de

treinamento, para ser decidido qual algoritmo utilizar nas próximas etapas. No exemplo dado a seguir, será respeitada a divisão de treino e teste do conjunto de dados. Assim, o classificador será induzido apenas com o conjunto de treino e será avaliado apenas com o conjunto de teste.

A seguir serão mostrados exemplos práticos de como utilizar cada um destes algoritmos com o conjunto de dados ECG5000.

O Código-Fonte 2.5 mostra um exemplo de aplicação do algoritmo baseado em distância do vizinho mais próximo. Neste caso, se aplica o algoritmo disponível na biblioteca `aeon` no conjunto de treino, instanciando-se os parâmetros para a classificação. Assim, quando se realiza uma predição no conjunto de testes, cada instância não rotulada tem sua similaridade calculada com base nas instâncias de treino. Baseando-se nas distâncias para um número de vizinhos estipulado pelo parâmetro k , o algoritmo vai determinar a qual rótulo aquela instância de teste pertence.

Código-Fonte 2.5. Classificação com o Algoritmo KNN.

```

1 from aeon.classification.distance_based import
    KNeighborsTimeSeriesClassifier
2 import numpy as np
3
4 ecg5000_train = np.genfromtxt('ECG5000_TRAIN.tsv',
    delimiter='\t')
5 ecg5000_test = np.genfromtxt('ECG5000_TEST.tsv',
    delimiter='\t')
6
7 x_train, y_train = ecg5000_train[1:], ecg5000_train[0]
8 x_test, y_test = ecg5000_test[1:], ecg5000_test[0]
9
10 knn = KNeighborsTimeSeriesClassifier()
11 knn.fit(x_train, y_train)
12
13 y_pred = knn.predict(x_test)
14
15 print(accuracy_score(y_test, y_pred))

```

Ao final do código é possível notar o cálculo da acurácia, que determina quantas instâncias de cada classe o algoritmo previu corretamente. A Figura 2.21 mostra a matriz de confusão para o algoritmo KNN no conjunto de dados. Nela é possível observar cada rótulo que o algoritmo previu corretamente, e nos casos de erro qual foi o rótulo atribuído pelo algoritmo para aquela instância no lugar do seu rótulo real. Como ocorre um desbalanceamento de classes neste conjunto, onde a maioria das classes são pertencentes aos rótulos 1 e 2, as outras classes que possuem poucos exemplos concentram grande parte dos erros do algoritmo. Desta forma, há pouco volume de instâncias nestas classes para o algoritmo aprender alguma espécie de padrão que permita uma predição correta.

No Código-Fonte 2.6 é possível observar a aplicação do modelo de aprendizado profundo InceptionTime para classificação no conjunto de dados ECG5000. A implementação baseia-se na utilização da biblioteca `tsai` [Oguiza 2022]. Note que com poucas

linhas de código é possível aplicar um algoritmo do estado-da-arte para classificação de séries temporais. O InceptionTime baseia-se em *InceptionBlocks* para capturar padrões e relações lineares e não lineares na estrutura das séries temporais. Contudo para utilizá-lo é preciso transformar as séries que normalmente são carregadas em um *array* de duas dimensões para três dimensões, sendo elas: o número de instâncias, o número de canais e a última dimensão o tamanho da série ou a quantidade de observações.

Código-Fonte 2.6. Classificação com o InceptionTime.

```

1 from tsai.all import *
2 import numpy as np
3
4 ecg5000_train = np.genfromtxt('ECG5000_TRAIN.tsv',
5     delimiter='\t')
6 ecg5000_test = np.genfromtxt('ECG5000_TEST.tsv',
7     delimiter='\t')
8
9 x_train, y_train = ecg5000_train[1:], ecg5000_train[0]
10 x_test, y_test = ecg5000_test[1:], ecg5000_test[0]
11
12 x_train = np.reshape(x_train, (x_train.shape[0], 1,
13     x_train.shape[1]))
14 x_test = np.reshape(x_test, (x_test.shape[0], 1,
15     x_test.shape[1]))
16
17 train_ds = TSDataset(x_train, y_train - 1, types=(TSTensor,
18     TSLabelTensor))
19 train_dl = DataLoader(train_ds, bs=128, num_workers=0)
20
21 test_ds = TSDataset(x_test, y_test - 1, types=(TSTensor,
22     TSLabelTensor))
23 test_dl = DataLoader(test_ds, bs=128, num_workers=0)
24 dls = DataLoaders(train_dl, test_dl,
25     device=default_device())
26
27 num_classes = len(np.unique(y_train))
28 model = InceptionTime(1, num_classes)
29
30 learn = Learner(dls, model, loss_func=nn.CrossEntropyLoss(),
31     metrics=accuracy)
32 learn.fit_one_cycle(25, lr_max=1e-2)
33
34 preds, labels = learn.get_preds(dl=test_dl)
35 print(accuracy_score(preds.argmax(dim=1).numpy(),
36     labels.numpy()))

```

A Figura 2.22 mostra a matriz de confusão resultante da predição do InceptionTime realizada nos dados de teste do conjunto ECG5000. Assim como na matriz de confusão do KNN, é possível notar que o comportamento é semelhante. Com métricas muito

semelhantes, necessita-se uma análise de outros fatores para a escolha dos modelos, tais como: custo computacional, volume de dados necessários, arquitetura da solução, entre outros fatores externos.

No caso da comparação entre o algoritmo de vizinho mais próximo e o InceptionTime, sempre que uma nova instância é inserida para a predição, o KNN precisa calcular todas as distâncias desta nova instância e das existentes para determinar o seu rótulo. Essa tarefa por muitas vezes pode ser custosa e tornar-se computacionalmente inviável em grandes volumes de dados. Porém, no caso do InceptionTime, o maior custo computacional está no treinamento da rede neural, uma vez treinada, para cada instância serão somente utilizados os pesos internos da rede para determinar seu rótulo, eliminando a necessidade de recalculá-las. Desta forma, mesmo com métricas e resultados semelhantes, é possível determinar um modelo que melhor se adéqua ao caso proposto, contudo vale lembrar que não existe um modelo melhor para todos os casos.

2.5.3. Regressão extrínseca

Com o crescente interesse em séries temporais nas últimas décadas, que vem se intensificando nos últimos anos, pesquisadores propuseram dezenas de algoritmos específicos para a classificação [Ruiz et al. 2020] e outras tarefas, como *forecasting*, de séries temporais. Por outro lado, há ainda desafios não superados pela literatura para este tipo de dados. Um exemplo se dá pela lacuna por diferentes tarefas de aprendizado, como a regressão extrínseca de séries temporais. Por “extrínseca”, entende-se que o alvo da predição é um valor externo à série, ao contrário do que acontece com o *forecasting*. Por exemplo, ao considerar séries temporais de fotopletismografia, a regressão extrínseca teria por objetivo estimar parâmetros clínicos, como a saturação de oxigênio no sangue ou concentração de hemoglobina.

Recentemente, um grupo de pesquisadores notou esse fato e constatou que a tarefa de regressão é uma necessidade em diversos domínios de aplicação [Tan et al. 2021]. Dessa forma, criaram um repositório de conjuntos de dados de regressão em séries temporais e realizaram experimentos iniciais com diversos algoritmos⁴. A partir dessa iniciativa, foram propostas diversas novas técnicas para essa tarefa, incluindo algoritmos tradicionais aplicados a características extraídas das séries [Gay et al. 2021], adaptações de algoritmos bem estabelecidos em classificação [Guijo-Rubio et al. 2023] e de arquiteturas de redes neurais [Foumani et al. 2023].

Alguns algoritmos de classificação de séries temporais podem ser convertidos para lidar com regressão extrínseca de forma relativamente simples. Isso se deve ao fato de que muitos desses algoritmos consistem de uma ou mais etapas de transformação seguidas de um classificador final nos dados transformados.

Esse é o caso de um dos algoritmos mais bem avaliados em regressão extrínseca: o Random Convolutional Kernel Transform (ROCKET). O ROCKET utiliza um grande número de filtros convolucionais (em geral, 10000), construídos aleatoriamente a partir de diversos parâmetros, aplicando-os às séries temporais e extraíndo características da série resultante, por padrão, valor máxima (max) e proporção de valores positivos (ppv). Essas

⁴<http://tseregression.org/>

características formam uma grande tabela atributo-valor, que é então usada como entrada para um classificador linear.

Para adaptar o ROCKET à regressão extrínseca, basta substituir o classificador linear na ponta final por um regressor linear. No Código-Fonte 2.7, por exemplo, mostra-se a utilização de um regressor ROCKET utilizando a biblioteca `aeon` para a predição de frequência cardíaca por meio do conjunto de dados BIDMCHR.

Código-Fonte 2.7. Regressão com o ROCKET.

```

1 from aeon.datasets import load_from_tsfile
2 from aeon.transformations.panel.rocket import Rocket
3
4 from sklearn.pipeline import Pipeline
5 from sklearn.linear_model import RidgeCV
6 from sklearn.metrics import mean_squared_error
7
8 X_train, y_train = load_from_tsfile('BIDMCHR_TRAIN.ts')
9 X_test, y_test = load_from_tsfile('BIDMCHR_TEST.ts')
10
11 model = Pipeline([
12     ('transformer', Rocket()),
13     ('regressor', RidgeCV())
14 ])
15 model.fit(X_train, y_train)
16 y_pred = model.predict(X_test)
17
18 print(mean_squared_error(y_test, y_pred, squared=False))

```

Ao final, o Código-Fonte imprime o valor do erro quadrático médio entre os valores observados e os valores preditos. A título de reforçar o exemplo da utilização da biblioteca `aeon` para regressão extrínseca, o Código-Fonte 2.8 mostra como realizar a predição de valores de frequência respiratória por meio do conjunto de dados BIDMCRR.

Código-Fonte 2.8. Exemplo de utilização da biblioteca Aeon.

```

1 from aeon.datasets import load_from_tsfile
2 from aeon.regression.distance_based import \
3     KNeighborsTimeSeriesRegressor
4
5 # Carregar o dataset para a memoria
6 X_train, y_train = load_from_tsfile('BIDMCRR_TRAIN.ts')
7 X_test, y_test = load_from_tsfile('BIDMCRR_TEST.ts')
8
9 # Definir o modelo
10 model = KNeighborsTimeSeriesRegressor(
11     distance='dtw',
12     n_neighbors=3
13 )
14
15 # Ajustar o modelo aos dados

```

```

16 model.fit(X_train, y_train)
17
18 # Obter as previsões
19 y_pred = model.predict(X_test)
20
21 print(mean_squared_error(y_test, y_pred, squared=False))

```

2.6. Considerações Finais

A área de Aprendizado de Máquina para séries temporais está em plena expansão. Graças ao surgimento de novas demandas e tecnologias na área da Saúde, como saúde móvel (*mHealth*), esse domínio de conhecimento tem sido um dos principais motivadores para esse crescimento. Para que essas aplicações em Saúde possam estar cada vez mais presentes no nosso dia-a-dia, ainda é necessário trabalhar em propostas e avaliação tanto de novas técnicas quanto novas aplicações.

No entanto, o estado-da-arte em classificação e regressão extrínseca de séries temporais enfrenta um problema relacionado ao compromisso entre eficiência e eficácia. Os estudos experimentais mais recentes para essas tarefas apontam para o fato que os algoritmos mais precisos são também os mais custosos.

Ao se utilizar séries temporais como medições de sinais para auxiliar médicos e pacientes com os cuidados da saúde, é preciso que as previsões realizadas pelos modelos de Aprendizado de Máquina sejam corretas. Por isso, é necessário se investigar por algoritmos que sejam menos custosos e possam fornecer respostas iguais ou melhores do que os de maior custo.

Uma tendência na literatura recente da área é o aparecimento de novas propostas no contexto de aprendizado profundo. Porém, muitas das arquiteturas investigadas nesse domínio são adaptações diretas de arquiteturas projetadas para outros tipos de dados, como imagens e vídeos. Para avançar significativamente na criação de modelos neurais para séries temporais, é necessário investigar por técnicas específicas para esse tipo de dados.

Ainda, uma vez que há um custo considerável para a obtenção de dados rotulados no domínio da Saúde, há um grande espaço para se pesquisar por técnicas que trabalhem com diferentes suposições de rótulos. Por exemplo, a criação de modelos a partir de pouco volume de dados, de aprendizado semissupervisionado ou autossupervisionado, aprendizado de uma classe, entre outros.

Por fim, os autores gostariam de agradecer ao apoio a este trabalho. O desenvolvimento deste documento só foi possível graças aos auxílios relacionados aos processos nº 2022/03176-1, nº 2022/00305-5, nº 2023/02680-0 e nº 2023/05171-0, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

Referências

[Alsuliman et al. 2020] Alsuliman, T., Humaidan, D., and Sliman, L. (2020). Machine learning and artificial intelligence in the service of medicine: Necessity or potentiality?

Current research in translational medicine, 68(4):245–251.

- [Ang and Seng 2016] Ang, L.-M. and Seng, K. P. (2016). Big sensor data applications in urban environments. *Big Data Research*, 4:1–12.
- [Bagnall et al. 2017] Bagnall, A., Lines, J., Bostrom, A., Large, J., and Keogh, E. (2017). The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data mining and knowledge discovery*, 31:606–660.
- [Bagnall et al. 2015] Bagnall, A., Lines, J., Hills, J., and Bostrom, A. (2015). Time-series classification with cote: The collective of transformation-based ensembles. *IEEE Transactions on Knowledge and Data Engineering*, 27(9):2522–2535.
- [Barandas et al. 2020] Barandas, M., Folgado, D., Fernandes, L., Santos, S., Abreu, M., Bota, P., Liu, H., Schultz, T., and Gamboa, H. (2020). Tsfel: Time series feature extraction library. *SoftwareX*, 11:100456.
- [Becker 2006] Becker, D. E. (2006). Fundamentals of electrocardiography interpretation. *Anesthesia progress*, 53(2):53–64.
- [Bloomfield 2004] Bloomfield, P. (2004). *Fourier analysis of time series: an introduction*. John Wiley & Sons.
- [Christ et al. 2018] Christ, M., Braun, N., Neuffer, J., and Kempa-Liehr, A. W. (2018). Time series feature extraction on basis of scalable hypothesis tests (tsfresh—a python package). *Neurocomputing*, 307:72–77.
- [Dau et al. 2018] Dau, H. A., Keogh, E., Kamgar, K., Yeh, C.-C. M., Zhu, Y., Gharghabi, S., Ratanamahatana, C. A., Yanping, Hu, B., Begum, N., Bagnall, A., Mueen, A., Batista, G., and Hexagon-ML (2018). The ucr time series classification archive. https://www.cs.ucr.edu/~eamonn/time_series_data_2018/.
- [Deng et al. 2013] Deng, H., Runger, G., Tuv, E., and Vladimir, M. (2013). A time series forest for classification and feature extraction. *Information Sciences*, 239:142–153.
- [Durak and Arikan 2003] Durak, L. and Arikan, O. (2003). Short-time fourier transform: two fundamental properties and an optimal implementation. *IEEE Transactions on Signal Processing*, 51(5):1231–1242.
- [Ebrahimi et al. 2020] Ebrahimi, Z., Loni, M., Daneshtalab, M., and Gharehbaghi, A. (2020). A review on deep learning methods for ecg arrhythmia classification. *Expert Systems with Applications: X*, 7:100033.
- [El-Hajj and Kyriacou 2020] El-Hajj, C. and Kyriacou, P. A. (2020). A review of machine learning techniques in photoplethysmography for the non-invasive cuff-less measurement of blood pressure. *Biomedical Signal Processing and Control*, 58:101870.
- [El Maachi et al. 2020] El Maachi, I., Bilodeau, G.-A., and Bouachir, W. (2020). Deep 1d-convnet for accurate parkinson disease detection and severity prediction from gait. *Expert Systems with Applications*, 143:113075.

- [Faceli et al. 2020] Faceli, K., Lorena, A. C., Gama, J., Almeida, T. A., and Carvalho, A. C. P. L. F. (2020). *Inteligência Artificial—uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, 2 edition.
- [Fawaz et al. 2019] Fawaz, H. I., Forestier, G., Weber, J., Idoumghar, L., and Muller, P.-A. (2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33(4):917–963.
- [Fawaz et al. 2020] Fawaz, H. I., Lucas, B., Forestier, G., Pelletier, C., Schmidt, D. F., Weber, J., Webb, G. I., Idoumghar, L., Muller, P.-A., and Petitjean, F. (2020). InceptionTime: Finding AlexNet for time series classification. *Data Mining and Knowledge Discovery*, 34(6):1936–1962.
- [Foumani et al. 2023] Foumani, N. M., Miller, L., Tan, C. W., Webb, G. I., Forestier, G., and Salehi, M. (2023). Deep learning for time series classification and extrinsic regression: A current survey. *arXiv preprint arXiv:2302.02515*.
- [Fulcher and Jones 2017] Fulcher, B. D. and Jones, N. S. (2017). hctsa: A computational framework for automated time-series phenotyping using massive feature extraction. *Cell systems*, 5(5):527–531.
- [Gay et al. 2021] Gay, D., Bondu, A., Lemaire, V., and Boullé, M. (2021). Interpretable feature construction for time series extrinsic regression. In *Advances in Knowledge Discovery and Data Mining: 25th Pacific-Asia Conference, PAKDD 2021, Virtual Event, May 11–14, 2021, Proceedings, Part I*, pages 804–816. Springer.
- [Guijo-Rubio et al. 2023] Guijo-Rubio, D., Middlehurst, M., Arcencio, G., Silva, D. F., and Bagnall, A. (2023). Unsupervised feature based algorithms for time series extrinsic regression. *arXiv preprint arXiv:2305.01429*.
- [Herrmann et al. 2023] Herrmann, M., Tan, C. W., Salehi, M., and Webb, G. I. (2023). Proximity forest 2.0: A new effective and scalable similarity-based classifier for time series.
- [Hong et al. 2020] Hong, S., Zhou, Y., Shang, J., Xiao, C., and Sun, J. (2020). Opportunities and challenges of deep learning methods for electrocardiogram data: A systematic review. *Computers in biology and medicine*, 122:103801.
- [Hu et al. 2019] Hu, Y., Ji, C., Zhang, Q., Chen, L., Zhan, P., and Li, X. (2019). A novel multi-resolution representation for time series sensor data analysis. *Soft Computing*, pages 1–26.
- [Kashani and Barold 2005] Kashani, A. and Barold, S. S. (2005). Significance of qrs complex duration in patients with heart failure. *Journal of the American College of Cardiology*, 46(12):2183–2192.
- [Köppen 2000] Köppen, M. (2000). The curse of dimensionality. In *World Conference on Soft Computing in Industrial Applications*, volume 1, pages 4–8.

- [Kwapisz et al. 2011] Kwapisz, J. R., Weiss, G. M., and Moore, S. A. (2011). Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2):74–82.
- [Lee et al. 2022] Lee, J., Yeom, I., Chung, M. L., Kim, Y., Yoo, S., and Kim, E. (2022). Use of mobile apps for self-care in people with parkinson disease: systematic review. *JMIR mHealth and uHealth*, 10(1):e33944.
- [Lines and Bagnall 2015] Lines, J. and Bagnall, A. (2015). Time series classification with ensembles of elastic distance measures. *Data Mining and Knowledge Discovery*, 29(3):565–592.
- [Lines et al. 2018] Lines, J., Taylor, S., and Bagnall, A. (2018). Time series classification with hive-cote: The hierarchical vote collective of transformation-based ensembles. *ACM Transactions on Knowledge Discovery from Data*, 12(5):1–35.
- [Lubba et al. 2019] Lubba, C. H., Sethi, S. S., Knaute, P., Schultz, S. R., Fulcher, B. D., and Jones, N. S. (2019). catch22: Canonical time-series characteristics: Selected through highly comparative time-series analysis. *Data Mining and Knowledge Discovery*, 33(6):1821–1852.
- [Lucas et al. 2019] Lucas, B., Shifaz, A., Pelletier, C., O’Neill, L., Zaidi, N., Goethals, B., Petitjean, F., and Webb, G. I. (2019). Proximity forest: an effective and scalable distance-based classifier for time series. *Data Mining and Knowledge Discovery*, 33(3):607–635.
- [Martinez-Ríos et al. 2022] Martinez-Ríos, E., Montesinos, L., and Alfaro-Ponce, M. (2022). A machine learning approach for hypertension detection based on photoplethysmography and clinical data. *Computers in Biology and Medicine*, 145:105479.
- [Mazzu-Nascimento et al. 2020] Mazzu-Nascimento, T., de Oliveira Leal, Â. M., Nogueira-de Almeida, C. A., de Avó, L. R. d. S., Carrilho, E., and Silva, D. F. (2020). Noninvasive self-monitoring of blood glucose at your fingertips, literally!: Smartphone-based photoplethysmography. *International Journal of Nutrology*, 13(02):048–052.
- [Middlehurst and Bagnall 2022] Middlehurst, M. and Bagnall, A. (2022). The fresh-prince: A simple transformation based pipeline time series classifier. In *Pattern Recognition and Artificial Intelligence: Third International Conference, ICPRAI 2022, Paris, France, June 1–3, 2022, Proceedings, Part II*, pages 150–161. Springer.
- [Middlehurst et al. 2020] Middlehurst, M., Large, J., and Bagnall, A. (2020). The canonical interval forest (cif) classifier for time series classification. In *2020 IEEE International Conference on Big Data (Big Data)*, pages 188–195.
- [Middlehurst et al. 2021] Middlehurst, M., Large, J., Flynn, M., Lines, J., Bostrom, A., and Bagnall, A. (2021). Hive-cote 2.0: a new meta ensemble for time series classification. *Machine Learning*, 110(11-12):3211–3243.
- [Mitchell 1997] Mitchell, T. M. (1997). Machine learning.

- [Morid et al. 2023] Morid, M. A., Sheng, O. R. L., and Dunbar, J. (2023). Time series prediction using deep learning methods in healthcare. *ACM Transactions on Management Information Systems*, 14(1):1–29.
- [Oguiza 2022] Oguiza, I. (2022). tsai - a state-of-the-art deep learning library for time series and sequential data. Github.
- [Pereira et al. 2020] Pereira, T., Tran, N., Gadhoumi, K., Pelter, M. M., Do, D. H., Lee, R. J., Colorado, R., Meisel, K., and Hu, X. (2020). Photoplethysmography based atrial fibrillation detection: a review. *NPJ digital medicine*, 3(1):3.
- [Perpetuini et al. 2021] Perpetuini, D., Chiarelli, A. M., Cardone, D., Filippini, C., Rinnella, S., Massimino, S., Bianco, F., Bucciarelli, V., Vinciguerra, V., Fallica, P., et al. (2021). Prediction of state anxiety by machine learning applied to photoplethysmography data. *PeerJ*, 9:e10448.
- [Ruiz et al. 2020] Ruiz, A. P., Flynn, M., Large, J., Middlehurst, M., and Bagnall, A. (2020). The great multivariate time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data Mining and Knowledge Discovery*, pages 1–49.
- [Salari et al. 2022] Salari, N., Hosseinian-Far, A., Mohammadi, M., Ghasemi, H., Khaizaie, H., Daneshkhah, A., and Ahmadi, A. (2022). Detection of sleep apnea using machine learning algorithms based on ecg signals: A comprehensive systematic review. *Expert Systems with Applications*, 187:115950.
- [Schäfer 2015] Schäfer, P. (2015). The boss is concerned with time series classification in the presence of noise. *Data Mining and Knowledge Discovery*, 29(6):1505–1530.
- [Schäfer and Höggqvist 2012] Schäfer, P. and Höggqvist, M. (2012). Sfa: a symbolic fourier approximation and index for similarity search in high dimensional datasets. In *EDBT '12: Proceedings of the 15th International Conference on Extending Database Technology*, pages 516–527.
- [Silva 2017] Silva, D. F. (2017). *Large-Scale Similarity-Based Time Series Mining*. PhD thesis, Universidade de São Paulo, São Carlos.
- [Silva et al. 2023] Silva, D. F., de M. Júnior, J. G. B., Domingues, L. V., and Mazzu-Nascimento, T. (2023). Hemoglobin estimation from smartphone-based photoplethysmography with small data. In *Computer-Based Medical Systems*, page No prelo. IEEE.
- [Silva et al. 2018] Silva, D. F., Giusti, R., Keogh, E., and Batista, G. E. (2018). Speeding up similarity search under dynamic time warping by pruning unpromising alignments. *Data Mining and Knowledge Discovery*, 32:988–1016.
- [Tan et al. 2020] Tan, C. W., Bergmei, C., Petitjean, F., Schmidt, D., Webb, G. I., Bagnall, A., and Keogh, E. (2020). The monash, uea & ucr time series extrinsic regression archivee. <http://tseregression.org/>.

- [Tan et al. 2021] Tan, C. W., Bergmeir, C., Petitjean, F., and Webb, G. I. (2021). Time series extrinsic regression. *Data Mining and Knowledge Discovery*, pages 1–29.
- [Thoms et al. 2017] Thoms, L.-J., Colicchia, G., and Girwidz, R. (2017). Phonocardiography with a smartphone. *Physics Education*, 52(2):023004.
- [WHO 2011] WHO, W. H. O. (2011). mhealth: new horizons for health through mobile technologies. *mHealth: new horizons for health through mobile technologies*.
- [Wolpert 2002] Wolpert, D. H. (2002). The supervised learning no-free-lunch theorems. *Soft computing and industry*, pages 25–42.
- [Yeh et al. 2018] Yeh, C.-C. M., Zhu, Y., Ulanova, L., Begum, N., Ding, Y., Dau, H. A., Zimmerman, Z., Silva, D. F., Mueen, A., and Keogh, E. (2018). Time series joins, motifs, discords and shapelets: a unifying view that exploits the matrix profile. *Data Mining and Knowledge Discovery*, 32(1):83–123.

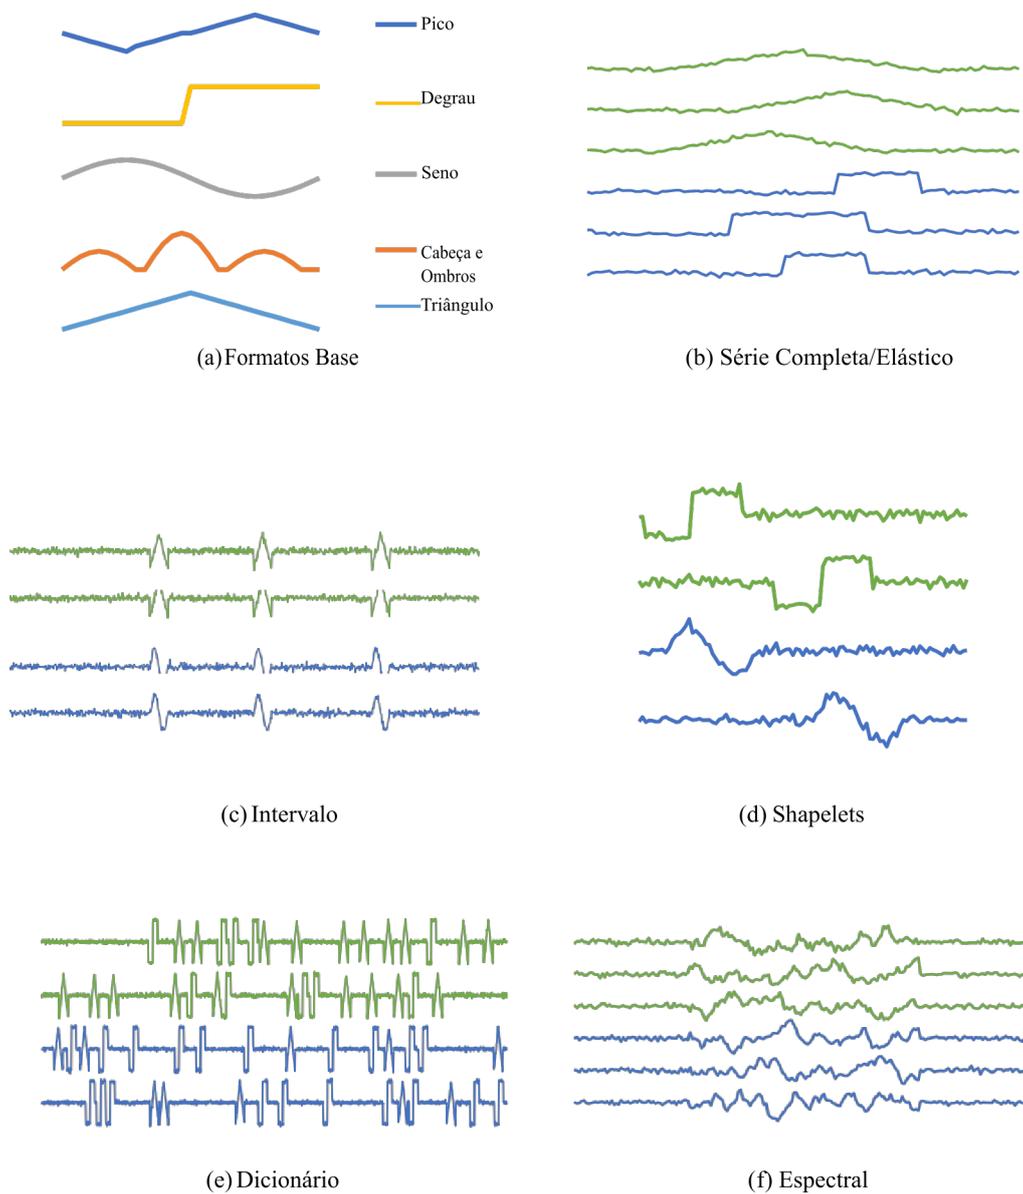


Figura 2.16. Ilustração dos domínios considerados pelos modelos do HIVE-COTE. Adaptado de [Lines et al. 2018].

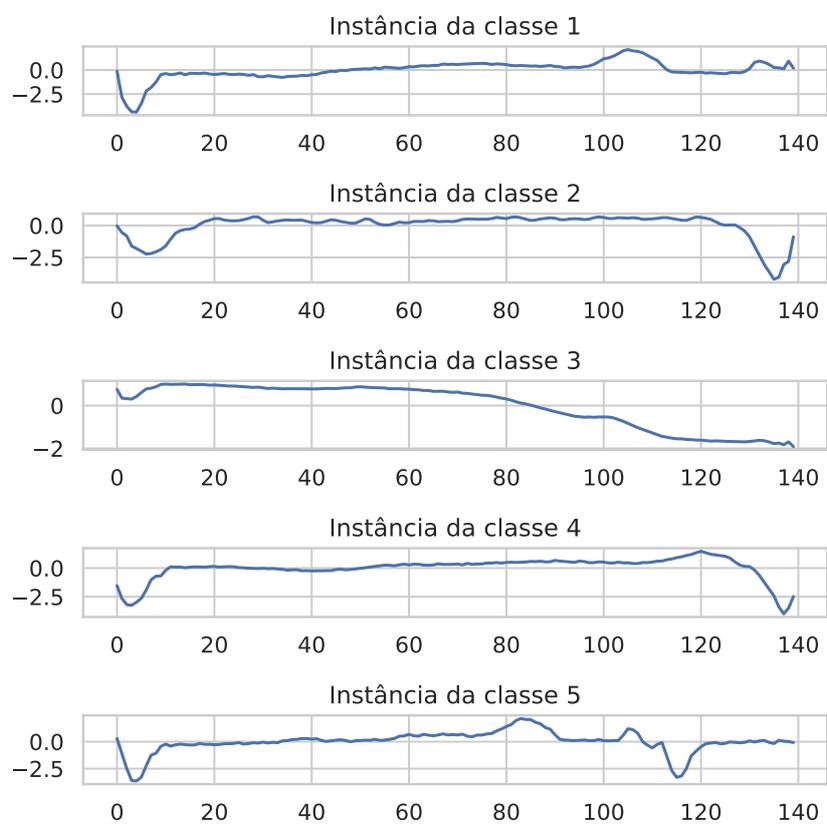


Figura 2.17. Exemplos de instâncias contidas em cada classe do conjunto de dados ECG5000.

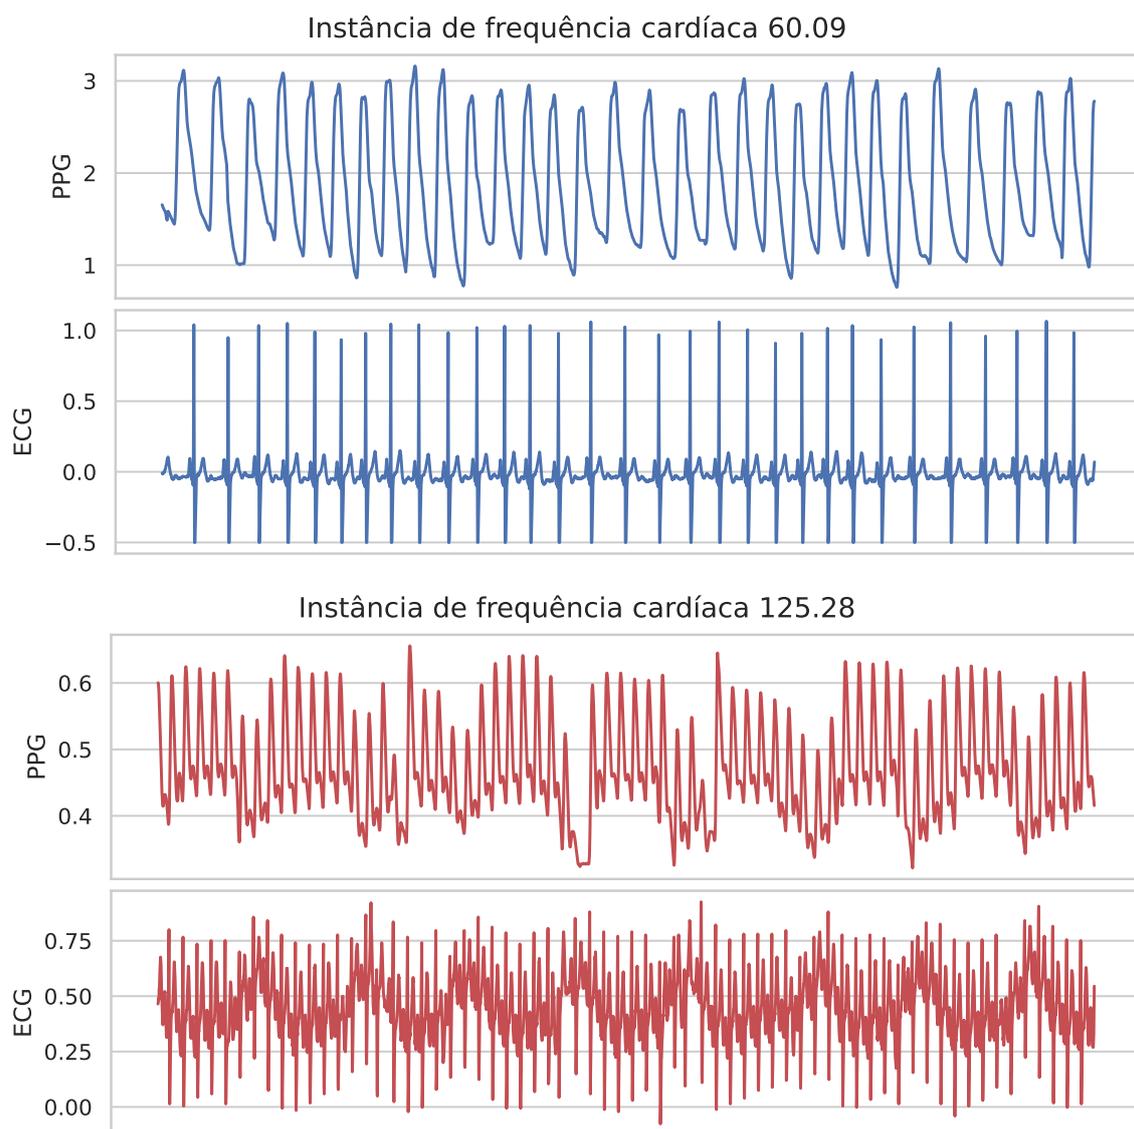


Figura 2.18. Exemplos de instâncias do conjunto de dados BIDMCHR com suas respectivas frequências cardíacas.

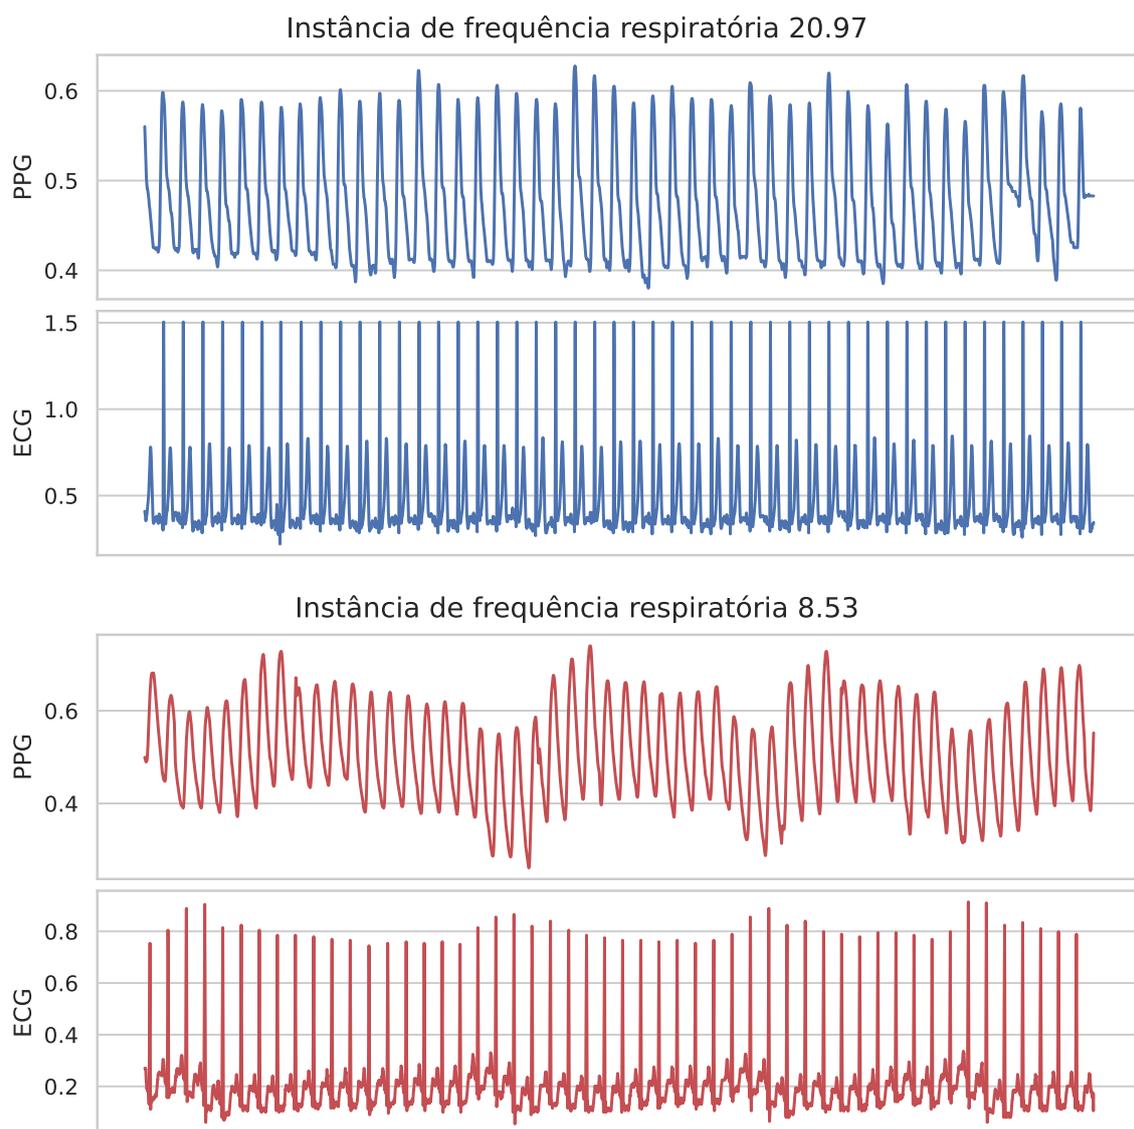


Figura 2.19. Exemplos de instâncias do conjunto de dados BIDMCRR com suas respectivas frequências respiratórias.

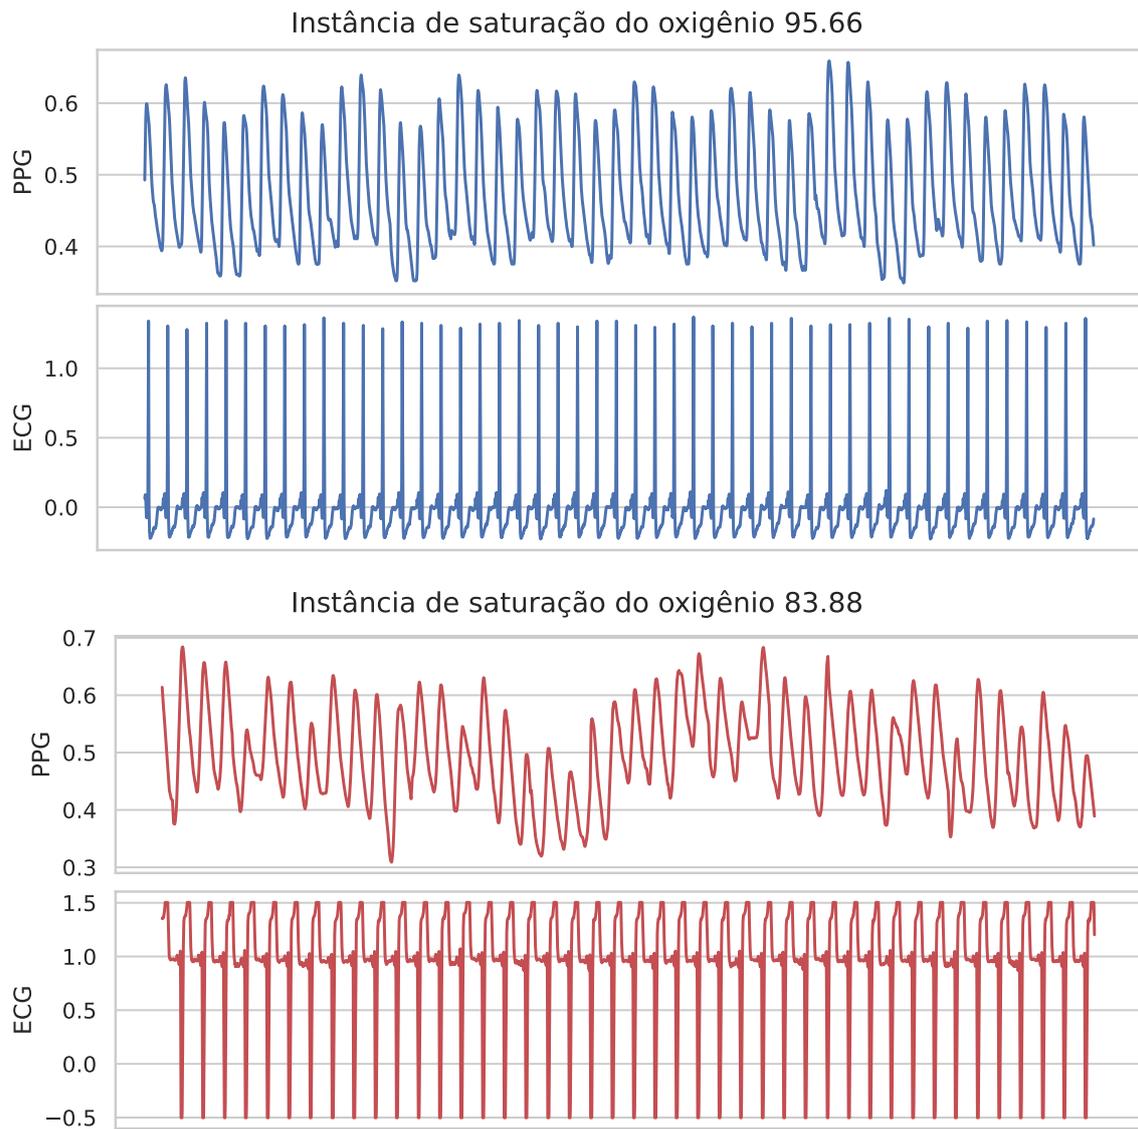


Figura 2.20. Exemplos de instâncias do conjunto de dados BIDMCSpO2 com suas respectivas saturações do oxigênio.

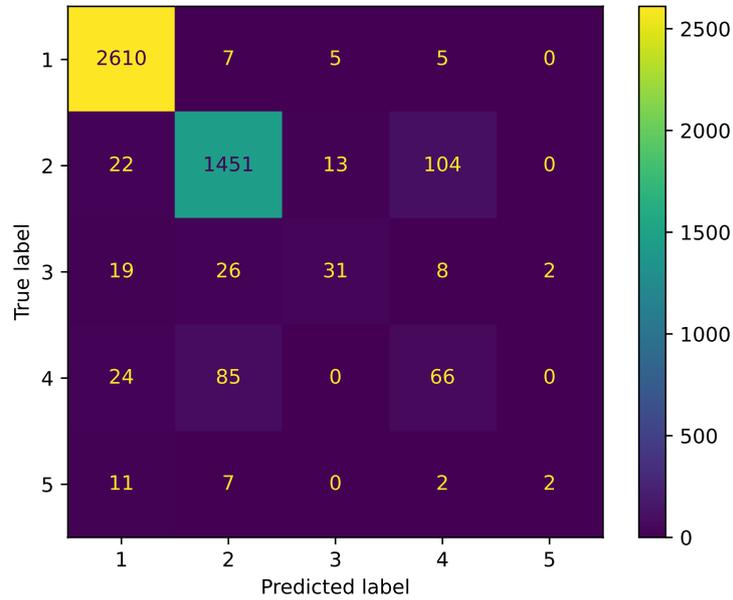


Figura 2.21. Matriz de Confusão gerada pelo Algoritmo KNN.

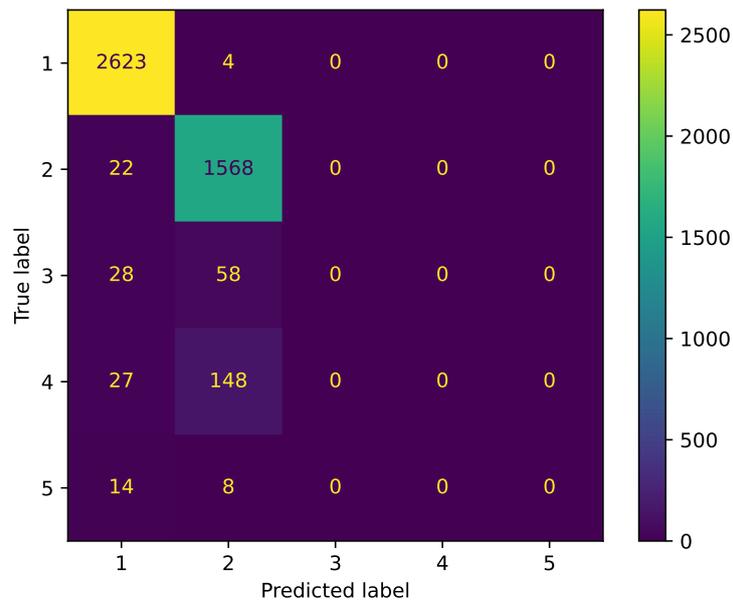


Figura 2.22. Matriz de Confusão gerada pelo InceptionTime após treinamento no conjunto de dados ECG5000.

Capítulo

3

Explicando as decisões com IAs: Demonstrando sua aplicação em imagens médicas

Elineide Silva dos Santos, Justino Duarte Santos, Luis Henrique Silva Vogado, Leonardo Pereira de Sousa, Hércio de Abreu Soares and Rodrigo de Melo Souza Veras

Abstract

It is already part of everyday being surrounded by technologies directed by Artificial Intelligences, from personal assistants to facial recognition. In the context of medicine is no different. It is remarkable the increasing insertion of technologies to support the diagnosis of diseases. However, in this context it is of paramount importance to take a step further: the explanation of the decisions taken by the AI models, especially those based on models of Deep Neural Networks (DNN). Achieving confidence and finding justification in the prediction of a DNN can hardly be achieved if the user does not have access to a satisfactory explanation for the process that led to its exit. In this short course, we will address theoretical aspects about explicability, its importance in the medical context, and we will know several methods of explanation of DNN models.

Resumo

Já faz parte do cotidiano sermos rodeados de tecnologias dirigidas por Inteligências Artificiais, desde assistentes pessoais até reconhecimentos faciais. No contexto da medicina não é diferente. É notável a crescente inserção de tecnologias de apoio ao diagnóstico de doenças. Entretanto, neste contexto é de suma importância dar um passo além: a explicação das decisões tomadas pelos modelos de IA, em especial as baseadas em modelos de Redes Neurais Profundas (DNN). Alcançar a confiança e encontrar justificativa na predição de uma DNN dificilmente pode ser alcançado se o usuário não tiver acesso a uma explicação satisfatória para o processo que levou à sua saída. Neste minicurso, abordaremos aspectos teóricos sobre explicabilidade, sua importância no contexto médico, e conheceremos vários métodos de explicação de modelos DNN.

3.1. Introdução

Ao processar uma imagem é necessário seguir um conjunto de etapas, pois processamento digital de imagens não é uma tarefa trivial. A etapa inicial consiste na captura da imagem por meio de um sistema de aquisição, o qual captura e digitaliza uma cena para formato específico. A imagem resultante de um processo de digitalização, precisa ser representada de uma forma apropriada para uso computacional. Elas podem ser representadas em duas ou mais dimensões [Acharya and Ray 2005].

Atualmente, a Inteligência Artificial (IA) tenta resolver tarefas difíceis de serem descritas formalmente, por exemplo reconhecimento de fala, padrões e imagens, ou seja, ligados a intuição humana. Trata-se de um grande desafio para um computador a habilidade de entender conhecimentos passados e predizer/resolver problemas futuros. Nesse contexto, surgiu uma subárea da IA, o Aprendizado de Máquina (*Machine Learning* - ML) capaz de utilizar métodos computacionais para tratar esse desafio.

Em ML, a aprendizagem é feita por meio de treinamentos em banco de dados, que representam eventos e experiências passadas, possibilitando a construção de sistemas capazes de aprender de forma automática [Dundas and Chik 2011]. Uma área de aplicação da ML é a classificação de imagens, no qual quanto maior a quantidade de exemplos, maior a capacidade de predição dos classificadores gerados. Porém, em cenários reais, dispor de bases de dados com uma grande quantidade de exemplos rotulados nem sempre é fácil, na maioria das vezes, custosa.

Desse modo, podemos utilizar abordagens de *Data Augmentation*, em síntese compreendem técnicas computacionais com o objetivo de aumentar a quantidade de exemplos rotulados em um conjunto de dados e assim, melhorar os resultados obtidos [Taylor and Nitschke 2018]. O uso de *Data Augmentation* é evidente em algumas aplicações da classificação de imagens, como aplicações com imagens aéreas e médicas cujo os dados são limitados.

Uma das técnicas de aprendizado de máquina amplamente utilizada é o *Deep Learning*. Desenvolvida a partir de redes neurais artificiais que são capazes de reconhecer e classificar padrões. Atualmente, as redes neurais profundas (*Deep Neural Networks* - DNNs) auxiliam nos avanços de visão computacional, tem sua estrutura baseada em redes neurais artificiais, porém, as DNNs são modelos extremamente complexos, com milhões de parâmetros, e são conhecidos pela alta capacidade de ocorrer *overfitting*, devido à demanda por enormes quantidades de dados durante o treinamento e pela dificuldade em oferecer interpretabilidade dos modelos.

Modelos como regressões lineares, regressões logísticas, árvores de decisões e *KNearest Neighbors* (KNN) são de fácil entendimento, ainda que simples. Por outro lado, modelos baseados em redes neurais artificiais e, em particular, redes convolucionais, não têm explicação natural para seus resultados. Tais modelos são compostos por uma enorme quantidade de parâmetros que se relacionam de várias maneiras.

Apesar de redes convolucionais serem chamadas de modelos caixas pretas no contexto de interpretabilidade, isso não quer dizer que não há nenhuma maneira de investigar os mecanismos internos destes modelos. Pode-se empregar técnicas de interpretabilidade que são *model-agnostic* (ou que não dependem do modelo), como, por exemplo,

LIME, que utiliza a imagem de entrada para identificar regiões importantes para o modelo. Outras técnicas foram desenvolvidas especialmente para lidar com redes convolucionais, como CAM, Grad-CAM, *Guided Backpropagation*, dentre outras.

3.1.1. Representação Computacional de Imagens

Segundo Gomes e Velho [Gomes and Velho 1997], um modelo matemático é necessário para representação e manipulação de imagens no computador. Considerando que as imagens são captadas por meio da luz emitida pelos objetos, pode-se estabelecer um modelo abstrato de imagens visando a representação discreta e futura codificação para uma linguagem compreendida pelo computador.

No contexto matemático, uma imagem é uma função bidimensional $f(a, b)$ onde a e b são coordenadas planas, e a amplitude de f em qualquer par de coordenadas (a, b) é chamada de intensidade ou nível de cinza da imagem para um determinado ponto. Nesse contexto, quando tanto os valores a, b quanto o valor da amplitude f compreendem um conjunto finito, denota uma imagem digital [Gonzalez et al. 2002].

De modo geral, uma imagem digital pode ser descrita como uma matriz $m \times n$, onde cada parte da matriz equivale a intensidade (brilho) ou nível de cinza $f(a, b)$, essas partes são denominadas os *pixels* de uma imagem. Em imagens binárias os *pixels* tem valores 0 e 1, enquanto em imagens em tons de cinza, seus valores podem variar entre 0 e 255. Já uma imagem colorida, esse *pixel* é representado por três valores que variam de 0 a 255.

Em imagens coloridas que possuem múltiplas bandas de frequências, existe uma função de intensidade de brilho associada a cada uma das banda de frequências. A Figura 3.1 mostra um exemplo das bandas presentes no padrão RGB (Vermelho (*Red*), Verde (*Green*) e Azul (*Blue*), o mais popular utilizado.

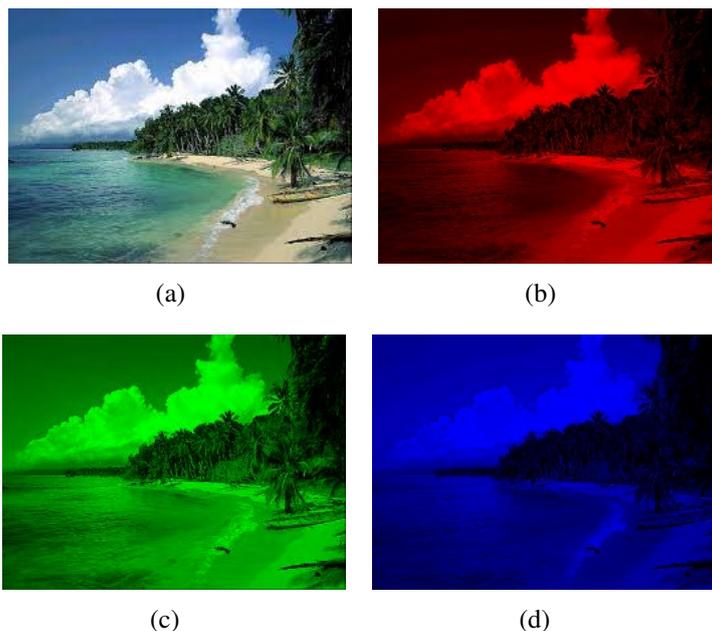


Figura 3.1. Imagens coloridas no padrão RGB.(a) RGB, (b) Vermelho, (c) Verde, (d) Azul.

Dessa maneira, na Figura 3.1 é possível notar que uma imagem colorida consiste em três imagens monocromáticas e a sobreposição dessas imagens compõem a imagem colorida, inclusive a mistura de cada uma dessas cores obtém-se as demais cores.

3.1.2. Técnicas de *Data Augmentation*

Dados limitados são um grande obstáculo na aplicação de modelos de aprendizagem profunda, como redes neurais convolucionais. Frequentemente, classes desequilibradas podem ser um obstáculo adicional, embora possa haver dados suficientes para algumas classes, igualmente importantes, mas classes abaixo da amostra sofrerão com baixa precisão específica da classe. Esse fenômeno é intuitivo. Se o modelo aprender com alguns exemplos de uma determinada classe, é menos provável prever a invalidação da classe e os aplicativos de teste [Shorten and Khoshgoftaar 2019].

As primeiras demonstrações que mostram a eficácia das técnicas de *Data augmentation* vêm de transformações simples, como inversão horizontal, aumento de espaço de cores e corte aleatório. Essas transformações codificam muitas das invariâncias discutidas anteriormente que apresentam desafios para as tarefas de reconhecimento de imagem [Shorten and Khoshgoftaar 2019].

3.1.2.1. Transformações Geométricas

Esta seção descreve técnicas capazes de modificar a forma, tamanho e posição dos componentes presentes dentro da imagem. Todos esses métodos são fundamentados em transformações geométricas e têm como característica principal a fácil implementação.

Flipping: Essa técnica faz uma inversão na imagem original, tal inversão pode ser na horizontal ou na vertical. Em geral, inverter o eixo horizontal é mais comum do que inverter o eixo vertical. Esse aumento é um dos mais fáceis de implementar e provou ser útil em conjuntos de dados como MNIST, ImageNet e CIFAR-10.

Rotação: É uma técnica que realiza os aumentos girando a imagem para a direita ou esquerda em um eixo entre 1° e 359° . O parâmetro do grau de rotação é responsável por garantir a segurança dos aumentos realizados pela rotação. Um detalhe significativo consiste em medida que o grau de rotação aumenta, os rótulos dos dados não são mantidos após a transformação [Shorten and Khoshgoftaar 2019].

Translação: Essa técnica pode mudar as imagens para a esquerda, direita, para cima ou para baixo. Essa característica pode ser vantajoso em conjuntos com distorções posicionais. Por exemplo, em um determinado conjunto de imagens centralizadas, o modelo seria mais eficiente se também fosse testado em imagens devidamente centralizadas. Nesse caso, a translação preserva as dimensões espaciais por meio do preenchimento com um valor constante (0 ou 255) ou um ruído (aleatório, gaussiano), o espaço restante proveniente da aplicação da técnica sobre a imagem.

Zoom / escala: Um zoom aleatório é obtido pelo argumento *zoom_range*. Um zoom menor que 1.0 amplia a imagem, enquanto um zoom maior que 1.0 diminui o zoom da imagem.

Shear / cisalhamento: Essa transformação inclina a forma da imagem. O con-

traste entre rotação e cisalhamento refere-se fixação de um eixo, durante a aplicação da transformação de cisalhamento. Em seguida a imagem é esticada até um determinado ângulo conhecido como ângulo de cisalhamento, então, o resultado alcançado é uma espécie de “alongamento” dessa imagem, característica ausente quando trata-se da rotação.

A Figura 3.2 mostra exemplos da aplicação do aumento de dados sobre a imagem de um gato.

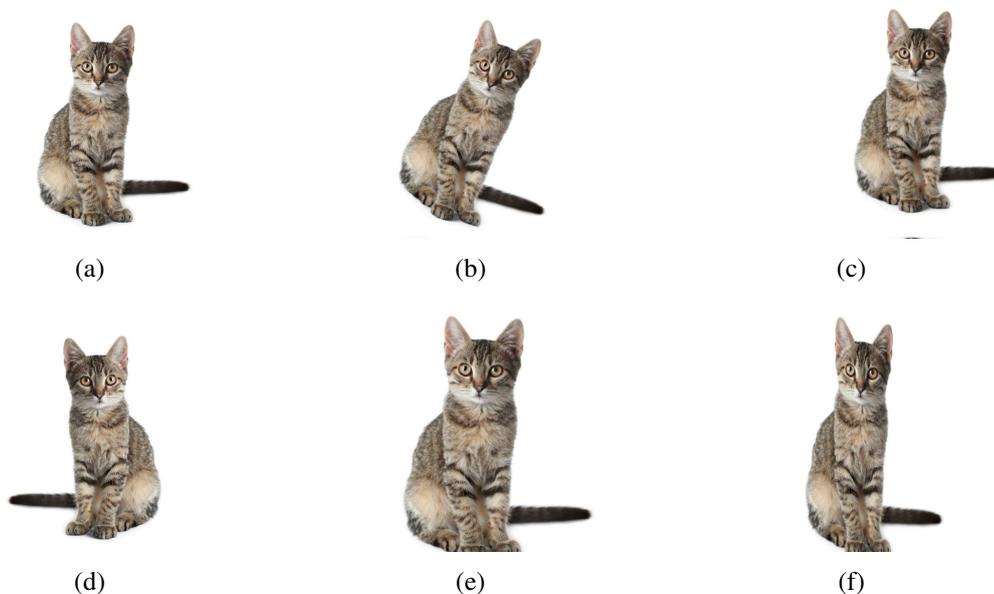


Figura 3.2. Aplicação de aumento de dados. (a) Imagem Original, (b) Rotação de 40°, (c) Translação de 20%, (d)Flipping Horizontal, (e) Zoom de 20% e (f) Cisalhamento de 20°.

3.2. Aprendizado Profundo

Deep Learning ou Aprendizagem Profunda é uma técnica de aprendizado de máquina desenvolvida a partir das Redes Neurais Artificiais (RNAs). As RNAs são modelos matemáticos que tentam simular algumas das estruturas neurais biológicas, possuindo capacidade computacional adquirida através do aprendizado e generalização [Haykin 2007]. Pode-se dizer então que as RNAs são capazes de reconhecer e classificar padrões e posteriormente generalizar o conhecimento adquirido. Na Figura 3.3 observamos um exemplo de RNA genérica com duas camadas densas.

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e, com isso, melhorar seu desempenho. O aprendizado em RNAs está normalmente associado à capacidade de as mesmas adaptarem os seus parâmetros como consequência da sua interação com o meio externo. O processo de aprendizado é iterativo e por meio dele a RNA deve melhorar o seu desempenho gradativamente à medida que interage com o meio externo [Rezende 2003]. Pode-se denominar o algoritmo de aprendizado como um conjunto de regras bem definidas para a solução de um problema de aprendizado [Haykin 2007]. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si,

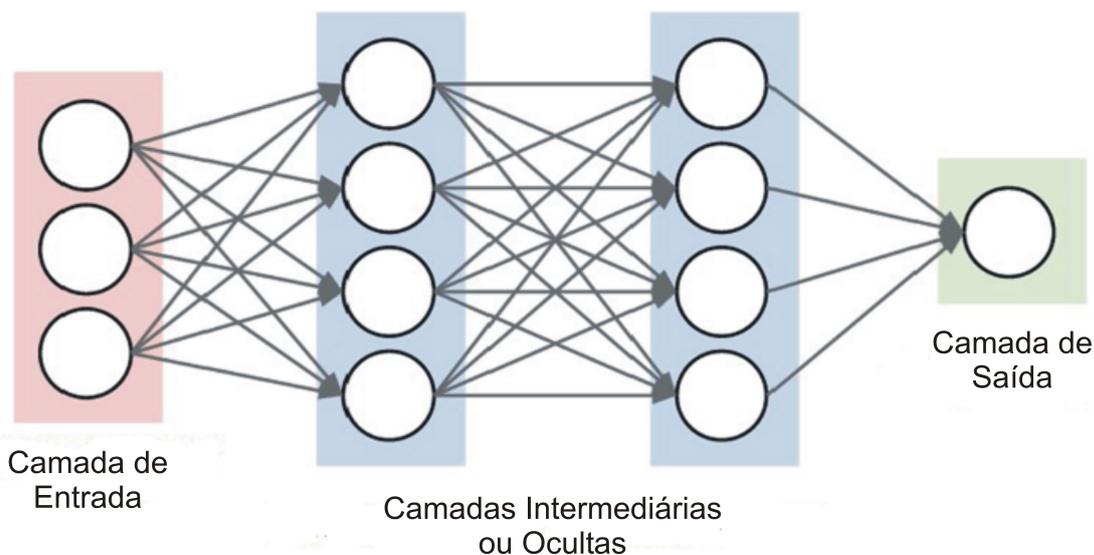


Figura 3.3. Exemplo de rede neural com duas camadas densas. Fonte: Sophiya and Jothilakshmi 2018

principalmente, pelo modo como os pesos são modificados.

O *Deep Learning* passa por grandes evoluções e vem se destacando no seu paradigma de “habilitar o computador a aprender a partir da observação dos dados”. O Aprendizado Profundo passou a ser aplicado em diversas áreas, em particular, mas não exclusivamente, as áreas de Visão Computacional, Processamento de Imagens, Computação Gráfica, entre outras mais [Ronneberger et al. 2015, Bejnordi et al. 2018]. As Redes neurais convolucionais começaram a aparecer como base para métodos do estado da arte em diversas aplicações. A competição *ImageNet* [Deng et al. 2009] teve grande impacto nesse processo, começando uma corrida para encontrar o modelo que seria capaz de superar o atual campeão nesse desafio de classificação de imagens, além de segmentação de imagens, reconhecimento de objetos, entre outras tarefas.

Uma das vantagens dos algoritmos de *Deep Learning* é sua capacidade de aprendizagem em grandes quantidades de dados de uma forma não-supervisionada, sendo assim uma ferramenta valiosa para *Big Data Analytics* onde a maioria dos dados são desta natureza, também designados por dados não-estruturados.

3.2.1. Aplicação de Deep Learning

O aprendizado de máquina e o *Deep Learning* são amplamente utilizados em muitos domínios, tais como: na medicina, em documentos, nos bancos, no processamento de linguagem natural, na recuperação de imagens, entre outros domínios.

Na medicina pode ser utilizada na detecção de células cancerígenas, restauração de imagem de ressonância magnética cerebral, impressão de genes, entre outras. Nos documentos, essas áreas poderão auxiliar na resolução de imagens de documentos históricos e segmentação de texto em imagens de documentos. Para o bancos poderá ser realizada uma previsão de ações e decisões financeiras [Pacheco and Pereira 2018].

O Processamento de Linguagem Natural são sistemas de recomendação como por

exemplo: Netflix que utiliza um sistema de recomendação para sugerir filmes aos usuários com base em seu interesse, análise de sentimentos e marcação de fotos. Para a recuperação de Informações poderão ser aplicadas os mecanismos de busca, pesquisa de texto e pesquisa de imagens como as utilizadas pelo Google, Amazon, Facebook e LinkedIn.

Deep Learning pode ser usada para:

- ⇒ Pré-processamento: que é uma maneira de realizar um ajuste ou melhoramento nos dados;
- ⇒ Extração de recursos: que é um processo para reconhecer algum padrão entre os dados e tem como intuito tornar o processo de decisão mais fácil durante a classificação;
- ⇒ Classificação: que é uma tarefa de predição e até uma classificação de várias classes.

Existem outras funcionalidades do *Deep Learning*, tais como regressão, reconhecimento de objetos, previsões, entre outras.

3.2.2. Redes Neurais Convolucionais

As CNNs fazem parte do conjunto de técnicas de *Deep Learning*. Essas redes convolucionais são uma classe de RNAs que modelam abstrações em alto nível através de imagens e camadas convolucionais dispostas de forma sequencial ou não. O conceito de CNN foi apresentado por Yann LeCun [Lecun et al. 1998] e Fukushima [Fukushima 1988] na década de 90. No entanto, apenas no século XXI essa tecnologia foi desenvolvida com eficácia.

Atualmente as CNNs são empregadas nos mais diversos problemas que envolvem a classificação, segmentação e detecção em imagens. Uma das principais vantagens na utilização de CNNs é a alta capacidade de aprender os mais diversos padrões que não são perceptíveis para outras técnicas tradicionais que utilizam descritores. No entanto, essa vantagem demanda um alto custo computacional e a necessidade de grandes bases de dados para o treinamento.

Camadas Convolucionais: Como as demais redes neurais artificiais, as CNNs apresentam estruturas no formato de camadas que auxiliam na extração de características, redução e classificação. A principal é a que denomina esse tipo de rede. As camadas convolucionais são compostas por uma quantidade c de filtros com tamanho $d \times d$ que irão extrair mapas de características ao serem convoluídos com as imagens de entrada ou com saídas de outras camadas.

A saída da convolução é denominada mapa de características ou *features map*. Esses mapas geralmente representam características gerais extraídas da imagem, como cor, borda, textura e forma. Um exemplo da operação de convolução é apresentada na Figura 3.4.

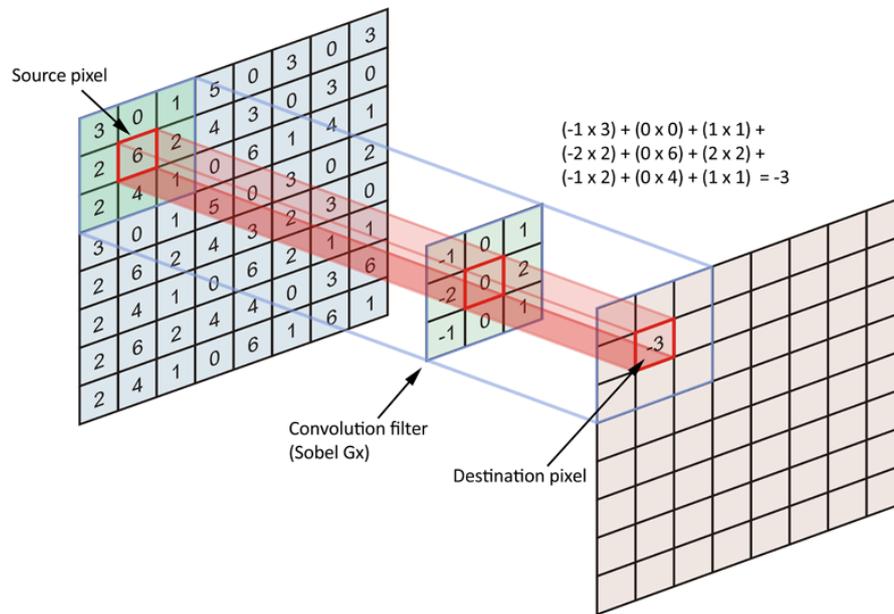


Figura 3.4. Exemplo de operação de convolução com tamanho de filtro 3x3.
 Fonte: Hachilif et al. 2019

Camadas de Pooling: Após as camadas convolucionais, geralmente são empregadas as de *pooling*. Esse tipo de camada reduz a dimensão espacial dos mapas gerados por camadas anteriores, consequentemente reduzindo o custo computacional. Dentre os diversos tipos, de *pooling* existe o *maxpooling*. Essa operação utiliza uma janela deslizante de tamanho $n \times n$ no mapa de características e para cada passo realizado, o valor máximo daquela janela é retirado. Na Figura 3.5 essa operação é ilustrada com um mapa aleatório.

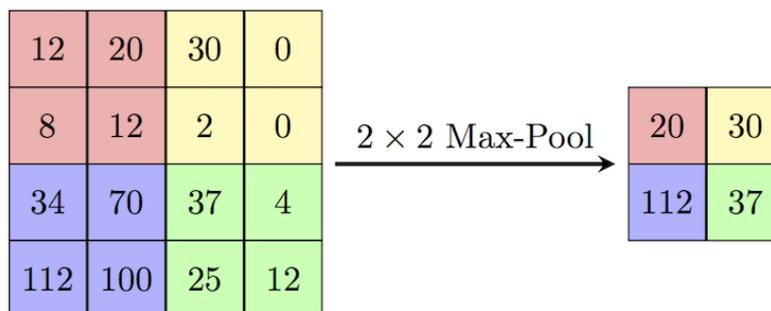


Figura 3.5. Exemplo de operação de maxpooling. Fonte: Gupta et al. 2018

Camadas Totalmente Conectadas: As camadas densas ou totalmente conectadas (*Fully-Connected layers* - FCs) foram apresentadas inicialmente nas RNAs. São constituídas de neurônios que representam pesos e guardam o aprendizado da rede neural. Nas CNN's elas apresentam a mesma função e geralmente aparecem ao final da arquitetura, após inúmeras camadas convolucionais. A operação que transforma os mapas de características em um vetor de neurônios é realizada pela camada *flatten*. A camada de classificação

presente nas CNNs é do tipo densa, no entanto, apresenta uma função de ativação do tipo *softmax*, enquanto as FCs contam com ativação por meio da ReLu.

3.2.2.1. Arquiteturas e ImageNet

A popularidade das CNNs cresceu durante o *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) [Russakovsky et al. 2015]. Essa competição ocorreu a partir de 2010 por 7 anos ininterruptos e teve como principais desafios a classificação de imagens e detecção de objetos em larga escala. O *dataset* popularmente conhecido como ImageNet possui mais de 1 milhão de imagens e cerca de mil classes.

Durante essa competição foram propostas arquiteturas que atualmente compõem o estado da arte, dentre elas temos a AlexNet [Krizhevsky et al. 2012], Inception ou GoogLeNet [Szegedy et al. 2015], VGGNet [Simonyan and Zisserman 2014] e ResNet [He et al. 2016]. Essas arquiteturas foram propostas por diversas companhias do ramo de tecnologia e cada uma possui características específicas que acabaram influenciando o desenvolvimento das posteriores. Abaixo elencaremos as mais relevantes nos respectivos anos de desafios e sua contribuição na literatura.

AlexNet: Em 2012 [Krizhevsky et al. 2012] propuseram a AlexNet, uma CNN com cinco camadas convolucionais seguidas de *maxpooling*, duas camadas totalmente conectadas e uma de classificação. Essa CNN obteve excelentes resultados no ILSVRC 2012 quando comparados com os anos anteriores. Em 2010 a taxa de erro era de 28,2%, em 2011 a evolução não foi como esperado e o erro baixou para 25,8%. Em 2012 o erro baixou para 16,4% com a utilização da AlexNet.

Nessa competição observamos a efetividade das CNNs quando comparadas com outras abordagens. Entretanto, os autores constataram que o desempenho foi obtido devido a profundidade da arquitetura e que isso representa um alto custo computacional. Ao todo, são 62,3 milhões de parâmetros, sendo assim necessário a utilização de GPUs para processar todos os dados em tempo hábil. Na Figura 3.6 observamos o *design* da AlexNet.

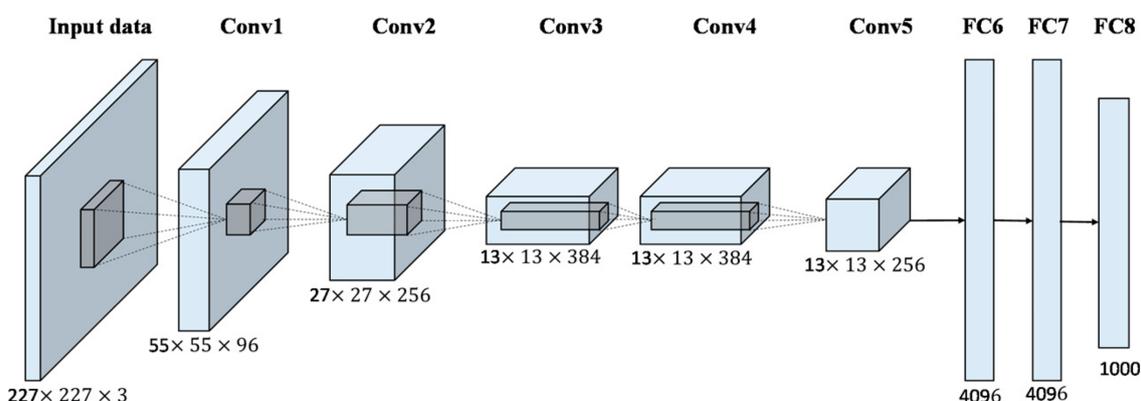


Figura 3.6. Arquitetura da AlexNet. Fonte: Shaees et al. 2020

GoogLeNet: Com o aumento popularidade do evento proporcionada pela Alex-

Net, as grandes companhias da tecnologia como a Google e a Microsoft montaram times para participar da competição. Em 2014, a Google e o seu time obtiveram os melhores resultados na competição com a GoogLeNet [Szegedy et al. 2015]. Essa CNN faz uso de módulos denominados *inception*. Eles são capazes de armazenar múltiplas camadas convolucionais em paralelo, mudando o paradigma e a rede deixa de ser sequencial. Utilizando essa estratégia, a GoogLeNet alcançou uma taxa de erro de 6,7% para a classificação de imagens. No entanto, para a localização de objetos, a erro foi de 26,4%, maior que o erro obtido pela VGG, sua principal concorrente na competição.

A estrutura da GoogLeNet conta com topologia de 22 camadas com cerca de 4 milhões de parâmetros. O *design* dessa CNN foi inspirado na LeNet [Lecun et al. 1998] com os módulos *inception*. Na Figura 3.7 observamos a arquitetura da CNN e a sua profundidade quando comparada com os vencedores anteriores.

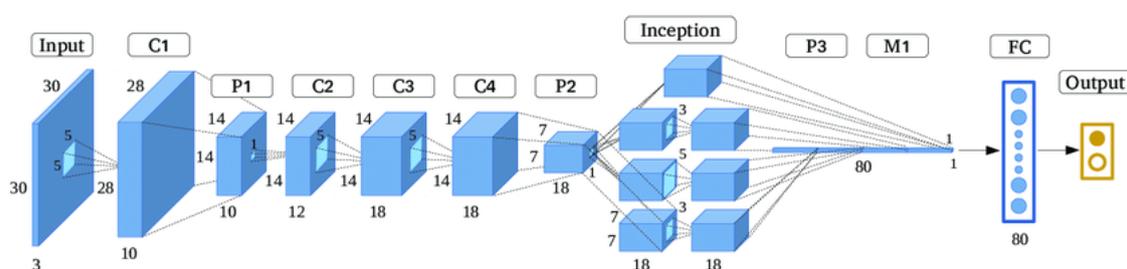


Figura 3.7. Arquitetura da GoogLeNet. Fonte: Guo et al. 2017

VGGNet: A principal concorrente da GoogLeNet no ILSVRC 2014 foi a VGGNet proposta por Simonyan and Zisserman [Simonyan and Zisserman 2014] com 16 camadas convolucionais dispostas de forma sequencial. No ILSVRC 2014, a VGGNet alcançou a segunda melhor taxa de erro para classificação de imagens com 7,3% e o melhor resultado para localização de objetos, com 25,3%.

A estratégia utilizada no desenvolvimento dessa CNN é a uniformidade no tamanho dos filtros convolucionais, sendo todos 3×3 . No entanto, a quantidade de filtros dobra em quase todos os blocos convolucionais, onde apenas o último mantém a mesma quantidade. A arquitetura dispõe de duas camadas totalmente conectadas com 4096 elementos.

Os autores justificaram a utilização de filtros 3×3 devido a quantidade de operações realizadas durante o convolução. Eles constataram que duas camadas com 3×3 executam uma quantidade próxima de operações quando comparadas com camadas de tamanho 5×5 .

ResNet: Proposta em 2015 [He et al. 2016], a Rede Neural Residual foi desenvolvida pelo time da Microsoft para solucionar o problema do desaparecimento do gradiente ou *vanishing gradient* que ocorre quando são adicionadas muitas camadas em um modelo sequencial. Com o excesso de camadas, ao ser propagado de volta na topologia, o excesso de operações decresce o valor do gradiente. Como consequência, o aprendizado se torna mais lento decorrente da saturação no desempenho da CNN, degradando com o tempo.

A ResNet venceu a competição ILSVRC-2015 com taxas de erro de apenas 3,56%, considerada uma taxa menor que a dos seres humanos que alcançam entre 5% a 10%.

Os autores propuseram a ResNet utilizando um estado de ablação que resultou em cinco arquiteturas com diferentes profundidades, sendo elas com 18, 34, 50, 101 e 152 camadas. Na Figura 3.8 apresentamos uma ilustração da CNN ResNet.

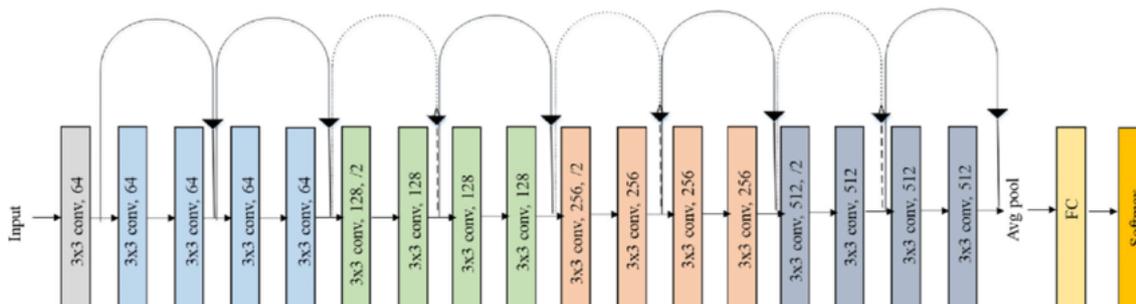


Figura 3.8. Arquitetura da ResNet com 18 camadas. Fonte: Ramzan et al. 2019

Em 2016, o vencedor da competição de classificação do ILSVRC foi a metodologia Trimps-Soushen. A taxa de erro obtida ao final da competição foi 2,99%. Nessa edição do evento os vencedores não apresentaram nenhuma inovação relacionada a estrutura das CNNs como nos anos anteriores. Diante disso, essa abordagem não se tornou conhecida como as demais CNNs.

Já em 2017, a *Squeeze-and-Excitation Network* (SENet) [Hu et al. 2018] foi a vencedora com 2,25% de taxa de erro. A denominação utilizada nesse tipo de rede neural vem dos blocos convolucionais *Squeeze-and-Excitation*. Esses blocos recalibram adaptativamente as características de saída de cada canal, modelando explicitamente as interdependências entre os canais. Diante disso, as redes neurais convolucionais consegue generalizar efetivamente diferentes bases de dados com a mesma estrutura.

Outras arquiteturas famosas não foram inicialmente propostas para o concurso, dentre elas temos a CaffeNet [Jia et al. 2014], InceptionV3 [Szegedy et al. 2016], Xception [Chollet 2017] e DenseNet [Huang et al. 2017]. Além das CNNs utilizadas para classificar imagens, foram propostas algumas com o objetivo de segmentar regiões.

U-Net: Sendo desenvolvida para segmentar imagens biomédicas, a U-Net é uma CNN que realiza a segmentação de uma determinada região tendo como base a sua marcação real [Ronneberger et al. 2015]. A ideia desenvolvida para essa CNN é de utilizar os mapas de características para contrair e expandir o vetor da imagem segmentada. Para realizar essa operação, a arquitetura é dividida em três partes, a contração, o gargalo e a expansão. A etapa de contração é realizada por blocos com camadas convolucionais com filtros 3×3 seguidos por *maxpooling* com janelas 2×2 .

A parte de expansão é considerada a mais importante, uma vez que possui blocos com camadas convolucionais e de *upsampling* que possuem o mesmo tamanho das camadas da fase de contração. Além dos blocos, são concatenados mapas de características da etapa de contração que permitem um melhor aprendizado durante a reconstrução da segmentação. O efeito proporcionado pela expansão mantém a simetria original da imagem de entrada, fazendo com que a saída seja de mesmo tamanho. Na Figura 3.9, apresentamos uma ilustração da arquitetura onde observamos as etapas descritas previamente.

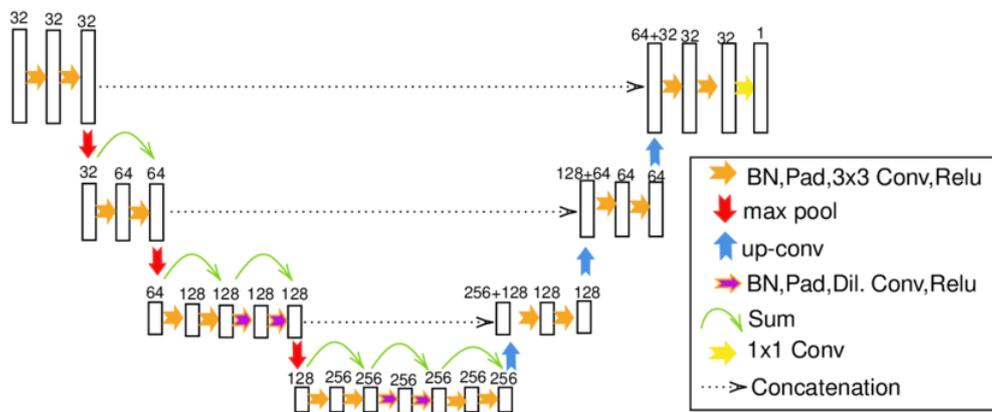


Figura 3.9. Arquitetura U-Net. Fonte: Furat et al. 2023

3.2.2.2. Arquitetura Genérica

Para exemplificar a construção de uma CNN e a definição das camadas convolucionais, totalmente conectadas e seus tamanhos, apresentamos uma arquitetura genérica desenvolvida para solucionar um problema simples de classificação. Neste caso, utilizamos o *dataset* MNIST. Essa base contém imagens com dimensão 24×24 e está dividida em 10 classes que representam os números de 0 a 9. Cada imagem possui um número escrito a mão livre e o objetivo é classificar os números de acordo com a sua respectiva classe.

Diante do problema apresentado, propomos uma CNN com duas camadas convolucionais, duas de *maxpooling* e uma camada totalmente conectada. Na Tabela 3.1, apresentamos a estrutura da CNN com o tamanho dos filtros, entrada e saída.

Tabela 3.1. Estrutura de uma CNN genérica.

Tipo de camada	Entrada	Qtd. de filtros	Tam. dos filtros	Passo	Saída
conv 1	$24 \times 24 \times 3$	64	$5 \times 5 \times 3$	1	$22 \times 22 \times 64$
maxpool 1	$22 \times 22 \times 64$	-	2×2	2	$11 \times 11 \times 64$
conv 2	$11 \times 11 \times 64$	32	$3 \times 3 \times 32$	1	$9 \times 9 \times 32$
maxpool 2	$9 \times 9 \times 32$	-	2×2	2	$4 \times 4 \times 32$
flatten	$4 \times 4 \times 32$	-	-	-	1×512
fc 1	-	1×512	-	-	512
fc 2	512	-	-	-	10

3.3. Métodos de Explicabilidade

A explicabilidade basicamente ajuda na interpretação da saída de um modelo por um usuário, já que esses modelos apresentam um padrão particular para cada tomada de decisão. Uma característica importante das explicações é sua semelhança com o tipo de dado utilizado no treinamento.

A Figura 3.10 mostra diferentes explicações conforme o tipo de dados associado. Dessa forma, quando o tipo de dados é uma imagem a sua explicação pode ser um *heat-*

map, enquanto para um tipo texto a explicação pode ser palavras destacadas no texto e em casos de tabelas de atributos, a explicação é apresentada como um conjunto de regras que descrevem as combinações de atributos capazes de levar às previsões.

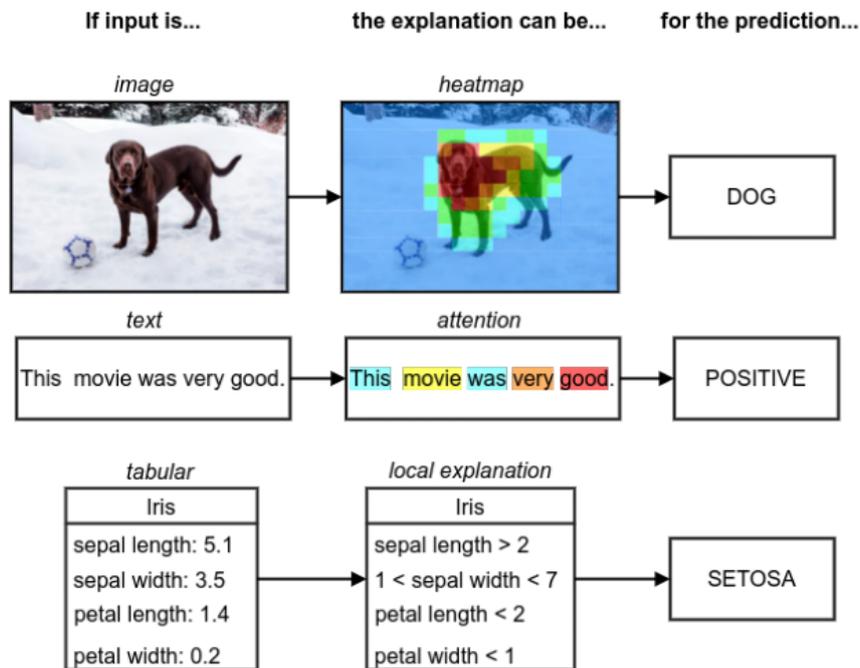


Figura 3.10. Exemplos de como as explicações podem parecer na prática. Fonte: Xie et al. 2020

Diante da enorme quantidade de parâmetros que caracterizam as CNN's, é necessário inspecionar cuidadosamente antes de ser implantado em qualquer ambiente médico, para que se tenha compreensão de seu funcionamento interno. Nesse contexto, a explicabilidade é importante para aumentar a compreensão dessas redes, bem como sua transparência, elevando a confiança dos seus usuários. Segundo Xie et al. [Xie et al. 2020] os métodos de explicabilidade podem ser categorizados em métodos de visualização, destilação de modelo e métodos intrínsecos.

As seções a seguir descrevem detalhadamente cada uma dessas categorias e na Figura 3.11 são listados alguns desses métodos.

3.3.1. Métodos de Visualização

Nos métodos de visualização a explicabilidade é demonstrada destacando as regiões que influenciam fortemente na saída da rede, os chamados *saliency maps* ou *heatmaps*. Eles podem ser subdivididos em métodos baseados em retropropagação e visualização baseada em perturbação.

Os métodos baseados em retropropagação mensuram a precisão de uma saída, dado às informações de entrada ou tal visualização pode ser feita avaliando a saída, desde que adote diferentes mapas de características. Enquanto na visualização por perturbação, avaliam a precisão realizando uma alteração na entrada (alterar ou remover recurso), em

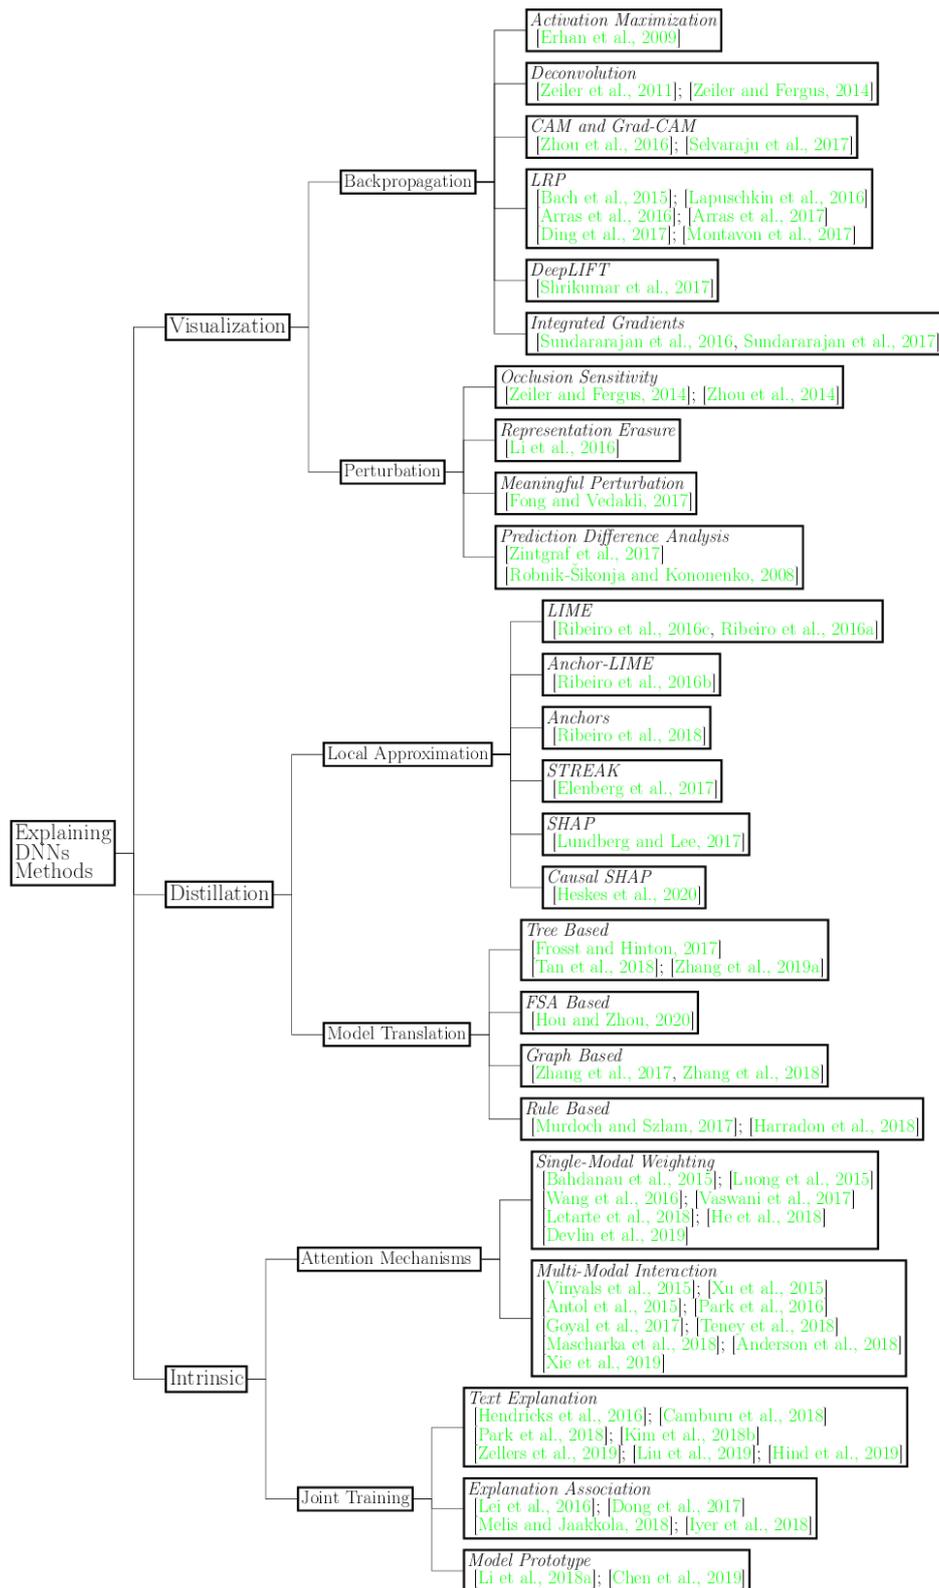


Figura 3.11. Métodos para explicar DNNs. Fonte: Xie et al. 2020

seguida, comparam a saída entre as redes alterada e original.

Alguns métodos que fazem parte desse campo são: *Activation Maximization* [Erhan et al. 2009], *textitDeconvolution* [Zeiler and Fergus 2014a, Zeiler et al. 2011], *CAM and Grad-CAM* [Zhou et al. 2016, Selvaraju et al. 2017, Lapuschkin et al. 2016], *Integrated Gradients* [Sundararajan et al. 2016, Sundararajan et al. 2017], *Occlusion Sensitivity* [Uchiyama et al. 2023, Zeiler and Fergus 2014b] e *Representation Erasure* [Li et al. 2016]. Dentre esses métodos, adotamos o Grad-CAM durante os experimentos para exemplificar a explicabilidade por método de visualização.

3.3.2. Destilação de Modelo

As abordagens utilizam um modelo de aprendizagem, no qual consiste em um modelo inerentemente explicável, popularmente conhecido como “white-bo”. Nesse modelo, busca-se distinguir as regras de decisão ou características de entrada que induzem as saídas da rede.

Esse modelo tem acesso às informações da rede treinada, assim como os dados de entrada originais, então, a interpretação desse modelo pode fornecer informações pouco profundas. Porém, é possível obter informações sobre a correlação, características e regras relacionadas a rede. A destilação do modelo possui duas categorias: aproximação local e tradução de modelos.

A aproximação local descreve um modelo de aprendizado simples sob um subconjunto de entrada pequeno. Nessa categoria, a grande motivação consiste em conseguir diferenciar a variedade de dados em uma área local ao invés de levar em consideração ao conjunto completo. Enquanto a tradução de modelos treinam uma estrutura menor organizado conforme o modelo completo. Em oposição a aproximação local, essa categoria usa o conjunto de dados inteiro.

Os métodos mais usados da categoria destilação de modelo são: LIME [Ribeiro et al. 2016b, Ribeiro et al. 2016a], SHAP [Lundberg and Lee 2017], *FSA Based* [Hou and Zhou 2018] e *Rule Based* [Murdoch and Szlam 2017]. Dentre esses métodos, adotamos o LIME durante os experimentos para exemplificar a explicabilidade por destilação de modelo.

3.3.3. Métodos Intrínsecos

Os modelos apresentam nas suas saídas explicações sobre suas decisões, ou seja, as explicações devem ser intrínsecas ao processo de projeção das arquiteturas e no treinamento. Como consequência essas estruturas são facilmente explicáveis, pois eles têm a capacidade de aprender as saídas precisas por entrada e as saídas que expressam uma explicação da ação da rede.

Contudo, nessa categoria o usuário precisa ter um conhecimento amplo sobre o campo de aplicação adotado, por essa razão os métodos intrínsecos são mais difíceis de serem implementados e provavelmente exigem um maior custo computacional, já que durante o treinamento ocorre a aplicação de diversos modelos para aprender as explicações intrinsecamente.

Duas tendências são seguidas por estes modelos, a primeira é a introdução de mecanismos de atenção a uma rede, e a segunda, incluem uma explicação complementar

à tarefa original do modelo, posteriormente, realiza um teste com a combinação de ambas. Dentre esses métodos temos o *Single-Modal Weighting* [Luong et al. 2015, Devlin et al. 2018], *Multi-Modal Interaction* [Goyal et al. 2017], *Text Explanation* [Zellers et al. 2019], *Explanation Association* [Li et al. 2017], *Model Prototype* [Chen et al. 2019].

3.4. Explicabilidade na Prática

Essa seção tem o objetivo de demonstrar a aplicabilidade da explicabilidade no conjunto de imagens da base pública ISIC 2016 [Gutman et al. 2016] usando todos os conceitos apresentados até o momento.

3.4.1. Base de Imagens

No problema abordado neste capítulo, apresentamos a base ISIC 2016 [Gutman et al. 2016], uma das base de imagens dermatoscópicas encontrada em diversas literaturas. Essa base de dados possui 900 imagens, divididas em imagens de lesões benignas e malignas. Vale ressaltar que utilizarmos o conjunto de treino do Desafio (Part 3: Lesion Classification), disponível em <https://challenge.isic-archive.com/landing/2016/>. A resolução das imagens de entrada variam entre 767×576 e 3024×2016 . Na Figura 3.12, apresentamos alguns exemplos da base utilizada no experimentos.

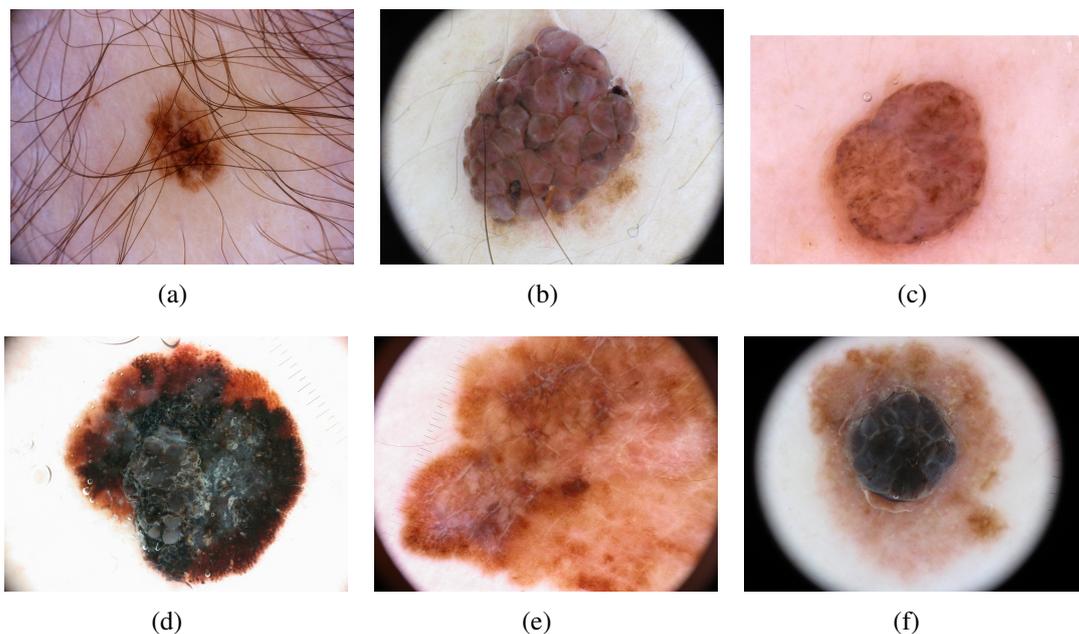


Figura 3.12. Exemplos de imagens da base ISIC 2016 (a, b, c) são benignas e (d, e, f) são lesões malignas.

- Pré-Processamento da base de imagens

Para realizar o experimento, precisamos realizar um pré-processamento das imagens, com a intenção de dividir a base disponibilizada em treino e teste. A separação é feita utilizando o código abaixo:

```
1 #Conectar com o Drive
```

```

2 from google.colab import drive
3 drive.mount('/content/drive')
4
5 #Importar bibliotecas
6 import pandas as pd
7 import os
8 import csv
9 import cv2
10 from sklearn.model_selection import train_test_split
11
12 tabela=pd.read_csv('/content/drive/MyDrive/Minicurso SBCAS/
13   ISBI2016_ISIC_Part3_Training_GroundTruth.csv',sep=",") #
14   Leitura de arquivo csv
15 #display(tabela) #Exibe na tela o arquivo lido
16
17 #Cria pastas
18 dir = '/content/drive/MyDrive/Minicurso SBCAS/' #Local das pastas
19 os.mkdir(dir+'base/')
20 os.mkdir(dir+'base/original/')
21 os.mkdir(dir+'base/train/')
22 os.mkdir(dir+'base/test/')
23 os.mkdir(dir+'base/original/malignant/')
24 os.mkdir(dir+'base/train/malignant/')
25 os.mkdir(dir+'base/test/malignant/')
26 os.mkdir(dir+'base/original/benign/')
27 os.mkdir(dir+'base/train/benign/')
28 os.mkdir(dir+'base/test/benign/')
29
30 mal=[] #armazena nomes imagens malignant
31 ben=[] #armazena nomes imagens benign
32
33 with open(dir+'ISBI2016_ISIC_Part3_Training_GroundTruth.csv','r')
34   as csvfile:
35     reader_obj = csv.reader(csvfile)
36     for row in reader_obj:
37         if str(row[1]) == 'malignant':
38             mal.append(str(row[0]))
39         if str(row[1]) == 'benign':
40             ben.append(str(row[0]))
41
42 caminho_base_descompactada = '/content/drive/MyDrive/Minicurso
43   SBCAS/ISBI2016_ISIC_Part3_Training_Data/
44   ISBI2016_ISIC_Part3_Training_Data/'
45
46 for i in range(0,len(mal)):
47     data = cv2.imread(caminho_base_descompactada+mal[i]+'.jpg')
48     cv2.imwrite(dir+'base/original/malignant/' + mal[i]+'.jpg',
49               data)
50
51 for i in range(0,len(ben)):
52     data = cv2.imread(caminho_base_descompactada+ben[i]+'.jpg')
53     cv2.imwrite(dir+'base/original/benign/' + ben[i]+'.jpg',data)
54
55 #Dividir base em conjunto de treino 80% e teste (20%)
56 trainMal, testMal = train_test_split(mal, train_size=0.8)

```

```

51 trainBen, testBen = train_test_split(ben, train_size=0.8)
52
53 # Salva imagens em suas respectivas pastas treino malignas
54 for i in range(0, len(trainMal)):
55     data = cv2.imread(dir+'base//original/malignant'+trainMal[i]+'
56     .jpg')
57     cv2.imwrite(dir+'base/train/malignant/' + trainMal[i]+' .jpg',
58     data)
59
60 # Salva imagens em suas respectivas pastas teste malignas
61 for i in range(0, len(testMal)):
62     data = cv2.imread(dir+'base/original/malignant/'+testMal[i]+'
63     .jpg')
64     cv2.imwrite(dir+'base/test/malignant/' + testMal[i]+' .jpg',
65     data)
66
67 # Salva imagens em suas respectivas pastas treino benignas
68 for i in range(0, len(trainBen)):
69     data = cv2.imread(dir+'base/original/benign/'+trainBen[i]+'
70     .jpg')
71     cv2.imwrite(dir+'base/train/benign/' + trainBen[i]+' .jpg', data)
72
73 # Salva imagens em suas respectivas pastas teste benignas
74 for i in range(0, len(testBen)):
75     data = cv2.imread(dir+'base/original/benign/'+testBen[i]+'
76     .jpg')
77     cv2.imwrite(dir+'base/test/benign/' + testBen[i]+' .jpg', data)

```

3.4.2. Aprendizado profundo

- **Definição de Parâmetros Globais:** Define a rede a ser utilizada no teste, pode ser utilizada tanto a VGG-16 quanto a Resnet50. Ainda, deve-se definir por meio da variável “rede” se a rede testada possui arquitetura original ou houve alguma alteração. A quantidade de épocas (qt.depocas) é utilizada para limitar o treinamento da rede e “size_global” define o tamanho da entrada da rede.

```

1 #rede_utilizada = 'VGG-16'
2 rede_utilizada = 'Resnet50'
3
4 rede = 'original'
5 #rede = 'modificada'
6
7 qtdepocas=200
8
9 if rede == 'original':
10     size_global = 224 # usado para as redes originais
11
12 elif rede == 'modificada':
13     size_global = 112 # usado para as redes modificada

```

- **Criação das Redes Neurais:** Após a definição de parâmetros, pode-se criar a estrutura das redes neurais a serem aplicadas nos experimentos. Elas são definidas conforme o código a seguir:

```

1 from tensorflow.keras import layers
2 from keras.layers import Dense, GlobalAveragePooling2D,
  BatchNormalization
3 from tensorflow.keras.applications import VGG16, ResNet50
4 import tensorflow as tf
5 from tensorflow.keras import Model
6
7 def cria_minha_rede_VGG16():
8     if rede == 'original':
9         rede_model = VGG16(include_top=True, weights='imagenet')
10
11     elif rede == 'modificada':
12         rede_model = VGG16(include_top=False, weights='imagenet')
13
14     input = rede_model.input
15
16     # bloco 1
17     conv = rede_model.layers[1](input)
18     conv = rede_model.layers[2](conv)
19     bn = BatchNormalization()(conv)
20     max = rede_model.layers[3](bn)
21
22     # bloco 2
23     conv = rede_model.layers[4](max)
24     conv = rede_model.layers[5](conv)
25     bn = BatchNormalization()(conv)
26     max = rede_model.layers[6](bn)
27
28     # bloco 3
29     conv = rede_model.layers[7](max)
30     conv = rede_model.layers[8](conv)
31     conv = rede_model.layers[9](conv)
32     bn = BatchNormalization()(conv)
33     max = rede_model.layers[10](bn)
34
35
36     # bloco 4
37     conv = rede_model.layers[11](max)
38     conv = rede_model.layers[12](conv)
39     conv = rede_model.layers[13](conv)
40     bn = BatchNormalization()(conv)
41     max = rede_model.layers[14](bn)
42
43     # bloco 5
44     conv = rede_model.layers[15](max)
45     conv = rede_model.layers[16](conv)
46     conv = rede_model.layers[17](conv)
47     bn = BatchNormalization()(conv)
48     max = rede_model.layers[18](bn)
49
50     if rede == 'original':
51         x = rede_model.output
52
53     elif rede == 'modificada':
54         x = GlobalAveragePooling2D()(max) # (x)

```

```

55
56     x = Dense(512, activation='relu')(x)
57     predictions = Dense(4, activation='softmax')(x)
58
59     meu_modelo = Model(inputs=rede_model.input, outputs=
60     predictions)
61     meu_modelo.compile(optimizer='adam', loss=tf.losses.
62     SparseCategoricalCrossentropy(), metrics=['accuracy'])
63
64     print("VGG-16 512 e input_size = ", size_global)
65     meu_modelo.summary() #exibe o modelo criado
66
67     return meu_modelo
68
69 def cria_minha_rede_Resnet50():
70     if rede == 'original':
71         meu_modelo = ResNet50(include_top=True, weights='imagenet'
72         )
73         x = meu_modelo.output
74
75     elif rede == 'modificada':
76         meu_modelo = ResNet50(include_top=False, weights='imagenet
77         ')
78         x = meu_modelo.output
79         x = GlobalAveragePooling2D()(x)
80
81     x = Dense(512, activation='relu')(x)
82
83     predictions = Dense(4, activation='softmax')(x)
84     meu_modelo = Model(inputs=meu_modelo.input, outputs=
85     predictions)
86     meu_modelo.compile(optimizer='adam', loss=tf.losses.
87     SparseCategoricalCrossentropy(), metrics=['accuracy'])
88
89     meu_modelo.summary()
90
91     print("ResNet50 512 e input_size = ", size_global)
92
93     return meu_modelo

```

- **Aumento de Dados:** Nessa seção, defini-se os aumentos de dados aplicados na base ISIC 2016, nesse caso, optou-se pelo uso de rotação, translação, cisalhamento, zoom e flipping. A biblioteca utilizada foi “ImageDataGenerator” que permite a geração de imagens apenas no momento da execução do programa, sem a necessidade de alocar imagens na memória do computador/Drive. A definição dessas técnicas é descrita no código a seguir.

```

1 !pip install Keras-Preprocessing
2
3 from keras_preprocessing.image import ImageDataGenerator
4
5 def aumentodadosTrain():
6     #Imagens aumentadas apenas no momento do processamento

```

```

7     train_datagen = ImageDataGenerator(
8         rotation_range=40,
9         width_shift_range=0.2,
10        height_shift_range=0.2,
11        rescale=1. / 255,
12        shear_range=0.2,
13        zoom_range=0.2,
14        horizontal_flip=True,
15        vertical_flip=True,
16        fill_mode='reflect'
17    )
18
19    test_datagen = ImageDataGenerator(rescale=1./255)
20
21
22    train_generator = train_datagen.flow_from_directory(
23        traindata, # pasta treino
24        target_size=(size_global, size_global), #redimensiona
25        imagens
26        color_mode='rgb',
27        batch_size=32,
28        class_mode='binary')
29    return train_generator
30
31 def aumentodadosTest():
32     #Imagens aumentadas apenas no momento do processamento
33     train_datagen = ImageDataGenerator(
34         rotation_range=40,
35         width_shift_range=0.2,
36         height_shift_range=0.2,
37         rescale=1. / 255,
38         shear_range=0.2,
39         zoom_range=0.2,
40         horizontal_flip=True,
41         vertical_flip=True,
42         fill_mode='reflect'
43     )
44
45
46     test_datagen = ImageDataGenerator(rescale=1./255)
47
48
49     test_generator = test_datagen.flow_from_directory(
50         testdata, # pasta teste
51         target_size=(size_global, size_global), #redimensiona
52         imagens
53         color_mode='rgb',
54         batch_size=32,
55         class_mode='binary')
56     return test_generator

```

A Figura 3.13 apresenta alguns exemplos de imagens resultantes do aumento de dados na base ISIC 2016.

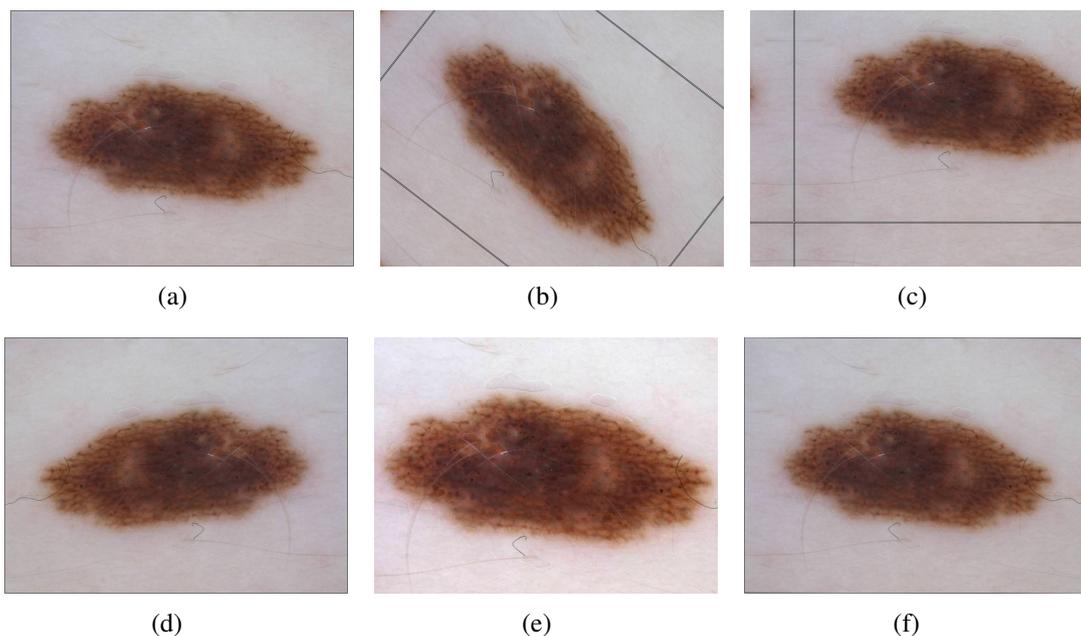


Figura 3.13. Aplicação de aumento de dados na base ISIC 2016. (a) Imagem Original, (b) Rotação de 40°, (c) Translação de 20%, (d)Flipping Horizontal, (e) Zoom de 20% e (f) Cisalhamento de 20°.

- Treinamento

```
1 !pip install gspread
2 !pip install keras
```

```
1 import os
2 from keras.callbacks import ModelCheckpoint
3 from keras_preprocessing.image import ImageDataGenerator
4 import matplotlib.pyplot as plt
5
6 #verificar o caminho da drive compartilhado
7 caminho_base='D:\\'
8 base_dir = caminho_base + 'base+'+'\\'
9 traindata = os.path.join(base_dir, 'train\\')
10 testdata = os.path.join(base_dir, 'test\\')
11
12 #Cria a rede neural a ser utilizada
13 if rede_utilizada == 'VGG16':
14     model = cria_minha_rede_VGG16()
15
16 elif rede_utilizada == 'Resnet50':
17     model = cria_minha_rede_Resnet50()
18
19 #Realiza aumento de dados
20 train_generator = aumentodedadosTrain()
21 test_generator = aumentodedadosTest()
22
23 #treinamento da rede
24 model.compile(optimizer='adam', loss=tf.losses.
    SparseCategoricalCrossentropy(), metrics=['accuracy'])
```

```

25 save_dir = os.path.join(os.getcwd(), "save_models") #salva o
    modelo criado
26 filepath = caminho_base + rede_utilizada + rede +str/qtdepcas) +
    'ep.h5'
27 checkpoint = ModelCheckpoint(os.path.join(save_dir, filepath),
    verbose=1, monitor='val_loss', save_best_only = True, mode='
    auto')
28
29 history = model.fit(train_generator,
30                     epochs=qtdepcas,
31                     callbacks = [checkpoint],
32                     validation_data=test_generator,
33                     validation_steps= test_generator.
    samples / test_generator.batch_size,
34                     verbose=1
35                     )
36
37 # Mostra grafico
38 plt.plot(history.history['accuracy'])
39 plt.plot(history.history['val_accuracy'])
40 plt.plot(history.history['loss'])
41 plt.plot(history.history['val_loss'])
42 plt.ylabel("Accuracy")
43 plt.xlabel("Epoch")
44 plt.legend(["Accuracy", "Validation Accuracy", "loss", "Validation
    Loss"])
45 plt.show()
46
47
48 print('Acuracia durante treinamento \n'+ str(history.history['
    accuracy']) + '\n')
49 print('Loss durante treinamento \n'+ str(history.history['loss'])
    + '\n')
50 print('Acuracia de validacao durante treinamento \n'+ str(history.
    history['val_accuracy']) + '\n')
51 print('Loss de validacao durante treinamento \n'+ str(history.
    history['val_loss']) + '\n')

```

- Cálculo de Métricas de Desempenho:

A avaliação das CNNs foi calculada com base nos valores obtidos pela matriz de confusão. Com base na matriz, obtemos quatro valores, denominados Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN). Nesse contexto, foram calculados as métricas de Acurácia , Precisão , *Recall*, *F1-score* e o *Kappa* (Equações 1, 2, 3, 4 e 5) da classificação:

$$Acuracia = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

$$Precisao = \frac{VP}{VP + FP} \quad (2)$$

$$Recall = \frac{VP}{VP + FN} \quad (3)$$

$$F1 - score = 2 * \frac{Precisao * Recall}{Precisao + Recall} \quad (4)$$

$$Kappa = \frac{observado - esperado}{1 - esperado} \quad (5)$$

O índice kappa considera todos os elementos da matriz de confusão e funciona como uma medida de associação usada para testar o grau de concordância na classificação. De acordo com Landis e Koch [Landis and Koch 1977], este índice assume valores entre 0 e 1, sendo o resultado qualificado em $k \leq 0.2$: Ruim; $0.2 < k \leq 0.4$: Moderado; $0.4 < k \leq 0.6$: Bom; $0.6 < k \leq 0.8$: Muito Bom and $k > 0.8$: Excelente.

No código mostrado a seguir é possível verificar o desempenho da CNN's com base nessas métricas sobre o conjunto de teste, salienta-se que durante essa etapa não é necessário realizar o aumento de dados do conjunto, tal processo só ocorre durante o treinamento das redes.

```

1 import os
2 from keras.models import load_model
3 from tensorflow.keras.preprocessing.image import
  ImageDataGenerator
4 from sklearn.metrics import confusion_matrix, accuracy_score,
  precision_score, recall_score, roc_auc_score,
  cohen_kappa_score, log_loss, f1_score
5
6 def encontrar(elemento):
7     pos_i = 0 # variavel provisoria de indice
8
9     for i in range (len(classe)): # procurar em todas as listas
  interna
10         if elemento == classe[i]: # se encontrarmos elemento
11             pos_i = i # guardamos o indice i
12             break
13     return (pos_i)
14
15
16 #verificar o caminho da drive compartilhado
17 caminho_base='/content/drive/MyDrive/Minicurso SBCAS/'
18 base_dir = caminho_base + "base/"
19
20 traindata = os.path.join(base_dir, 'train/')
21 testdata = os.path.join(base_dir, 'test/')
22
23
24 train_datagen = ImageDataGenerator(rescale=1. / 255)
25
26 test_datagen = ImageDataGenerator(rescale=1./255)
27
28
29 train_generator = train_datagen.flow_from_directory(
30     traindata, # This is the source directory for training
  images

```

```

31     target_size=(size_global, size_global), # All images will
    be resized to 224x224
32     color_mode='rgb',
33     batch_size=32, # Since we use binary_crossentropy
    loss, we need binary labels
34     class_mode='binary') #class_mode='categorical'
35
36 test_generator = test_datagen.flow_from_directory(
37     testdata,
38     target_size=(size_global, size_global),
39     color_mode='rgb',
40     batch_size=32,
41     class_mode='binary')
42
43 batch_size = 32
44
45 datagen_pred = ImageDataGenerator(rescale=1./255)
46
47 generator_pred = datagen_pred.flow_from_directory(
48     testdata,
49     target_size=(size_global, size_global),
50     batch_size=batch_size,
51     class_mode='binary',
52     shuffle=False)
53
54 datagen_pred = ImageDataGenerator(rescale=1. / 255)
55
56 generator_pred = datagen_pred.flow_from_directory(
57     testdata,
58     target_size=(size_global, size_global),
59     batch_size=batch_size,
60     class_mode='binary',
61     shuffle=False)
62 names=generator_pred_filenames
63
64 if rede_utilizada == 'VGG-16':
65     path=caminho_base + rede_utilizada + rede +str(qtdepocas) + '
    ep.h5'
66
67 elif rede_utilizada == 'Resnet50':
68     path=caminho_base + rede_utilizada + rede +str(qtdepocas) + '
    ep.h5'
69
70 classificador=load_model(path)
71 predicoeskfold = classificador.predict(generator_pred, steps=
    generator_pred.samples / generator_pred.batch_size) # Model.
    predict_generator` is deprecated
72
73 list_predicoes=[]
74
75 for i in range(len(predicoeskfold)):
76     classe=[]
77
78     classe1=(predicoeskfold[i][0])
79     classe2=(predicoeskfold[i][1])

```

```

80 classe.append(classe1)
81 classe.append(classe2)
82 classemay = max(classe1, classe2)
83 classe_definida=encontrar(classemay)
84 list_predicoes.append(classe_definida)
85
86 predicted_classes=list_predicoes
87 pred_oficial = generator_pred.classes
88
89 for i in range(len(predicted_classes)):
90     print('Imagem: ' + str(names[i]) + ' classe predita: ' + str(
91         predicted_classes[i]) + ' classe real: ' + str(pred_oficial[i]
92     ))
93
94 #Calculando
95 print('Rede: ' + rede_utilizada + ' - ' + rede)
96 print('Acuracia: ' + str(accuracy_score(pred_oficial,
97     predicted_classes)))
98 print('Recall: ' + str(recall_score(pred_oficial,
99     predicted_classes, average='weighted')))
100 print('Precisao: ' + str(precision_score(pred_oficial,
101     predicted_classes, average='weighted')))
102 print('Kappa: ' + str(cohen_kappa_score(pred_oficial,
103     predicted_classes)))
104 print('F1: ' + str(f1_score(pred_oficial, predicted_classes,
105     average='weighted')))
106 print('Matriz: ' + str(confusion_matrix(generator_pred.labels,
107     predicted_classes)))

```

```

Imagem: benign\ISIC_0000038.jpg classe predita: 0 classe real: 0
Imagem: benign\ISIC_0000039.jpg classe predita: 0 classe real: 0
Imagem: benign\ISIC_0000118.jpg classe predita: 1 classe real: 0
Imagem: benign\ISIC_0008236.jpg classe predita: 0 classe real: 0
Imagem: benign\ISIC_0011146.jpg classe predita: 0 classe real: 0
...
Imagem: malignant\ISIC_0000026.jpg classe predita: 0 classe real: 1
Imagem: malignant\ISIC_0000167.jpg classe predita: 0 classe real: 1
Imagem: malignant\ISIC_0000170.jpg classe predita: 1 classe real: 1
Imagem: malignant\ISIC_0000282.jpg classe predita: 1 classe real: 1
Imagem: malignant\ISIC_0000297.jpg classe predita: 0 classe real: 1
Imagem: malignant\ISIC_0000444.jpg classe predita: 1 classe real: 1
...
Rede: Resnet50 - original
Acurácia: 0.8287292817679558
Recall: 0.8287292817679558
Precisão: 0.8099092113340441
Kappa: 0.24633982538616517
F1: 0.7879076594764065
Matriz: [[143  3]
 [28  7]]

```

Figura 3.14. Resultado da classificação a partir da base ISIC 2016.

3.4.3. Aplicando a Explicabilidade

- Grad-CAM: essa seção será demonstrada a técnica Grad-CAM, esta técnica é uma das mais comuns no campo de visualização. Baseada no Class Activation Mapping (CAM), consiste em gerar mapas de calor sobre a imagem, baseados nos gradientes da rede. Assim pode-se visualizar regiões específicas da imagem que apresentaram maior contribuição para a classificação de uma determinada classe na camada de predição do modelo. Sua implementação se resume no seguinte código.

```

1 import numpy as np
2 import tensorflow as tf
3 from tensorflow import keras
4
5 from IPython.display import Image, display
6 import matplotlib.pyplot as plt
7 import matplotlib.cm as cm
8
9 from keras.models import load_model, Model
10 from keras.applications.imagenet_utils import preprocess_input
11
12
13
14 def get_img_array(img_path, size):
15     # 'img' is a PIL image of size 224x224
16     img = keras.utils.load_img(img_path, target_size=size)
17     # 'array' is a float32 Numpy array of shape (224, 224, 3)
18     array = keras.utils.img_to_array(img)
19     # We add a dimension to transform our array into a "batch"
20     # of size (1, 224, 224, 3)
21     array = np.expand_dims(array, axis=0)
22     return array
23
24
25
26 def make_gradcam_heatmap(img_array, model, last_conv_layer_name,
27     pred_index=None):
28     # First, we create a model that maps the input image to the
29     # activations
30     # of the last conv layer as well as the output predictions
31     grad_model = tf.keras.models.Model(
32         [model.inputs], [model.get_layer(last_conv_layer_name).
33         output, model.output]
34     )
35
36     # Then, we compute the gradient of the top predicted class for
37     # our input image
38     # with respect to the activations of the last conv layer
39     with tf.GradientTape() as tape:
40         last_conv_layer_output, preds = grad_model(img_array)
41         if pred_index is None:
42             pred_index = tf.argmax(preds[0])
43             class_channel = preds[:, pred_index]

```

```

43
44
45     # This is the gradient of the output neuron (top predicted or
46     # chosen)
47     # with regard to the output feature map of the last conv layer
48     grads = tape.gradient(class_channel, last_conv_layer_output)
49
50
51     # This is a vector where each entry is the mean intensity of
52     # the gradient
53     # over a specific feature map channel
54     pooled_grads = tf.reduce_mean(grads, axis=(0, 1, 2))
55
56     # We multiply each channel in the feature map array
57     # by "how important this channel is" with regard to the top
58     # predicted class
59     # then sum all the channels to obtain the heatmap class
60     # activation
61     last_conv_layer_output = last_conv_layer_output[0]
62     heatmap = last_conv_layer_output @ pooled_grads[..., tf.
63     newaxis]
64     heatmap = tf.squeeze(heatmap)
65
66     # For visualization purpose, we will also normalize the
67     # heatmap between 0 & 1
68     heatmap = tf.maximum(heatmap, 0) / tf.math.reduce_max(heatmap)
69     return heatmap.numpy()
70
71 def save_and_display_gradcam(img_path, heatmap, cam_path="cam.jpg"
72     , alpha=0.4):
73     # Load the original image
74     img = keras.preprocessing.image.load_img(img_path)
75     img = keras.preprocessing.image.img_to_array(img)
76
77     # Rescale heatmap to a range 0-255
78     heatmap = np.uint8(255 * heatmap)
79
80     # Use jet colormap to colorize heatmap
81     jet = cm.get_cmap("jet")
82
83     # Use RGB values of the colormap
84     jet_colors = jet(np.arange(256))[:, :3]
85     jet_heatmap = jet_colors[heatmap]
86
87     # Create an image with RGB colorized heatmap
88     jet_heatmap = keras.preprocessing.image.array_to_img(
89     jet_heatmap)
90     jet_heatmap = jet_heatmap.resize((img.shape[1], img.shape[0]))
91     jet_heatmap = keras.preprocessing.image.img_to_array(
92     jet_heatmap)

```

```

89
90     # Superimpose the heatmap on original image
91     superimposed_img = jet_heatmap * alpha + img
92     superimposed_img = keras.preprocessing.image.array_to_img(
93         superimposed_img)
94
95     # Save the superimposed image
96     superimposed_img.save(cam_path)
97
98     # Display Grad CAM
99     display(Image(cam_path))

```

```

1 path=caminho_base + rede_utilizada + rede +str(qtdepocas) + 'ep.h5
2
3 #Carrrega modelo treinado
4 path_model = load_model(path)
5
6 img_size = (size_global, size_global)
7
8 if rede_utilizada=='VGG-16':
9     # Ao utilizar VGG-16
10    last_conv_layer_name = "block5_pool"
11
12 elif rede_utilizada == 'Resnet50':
13     # Ao utilizar Resnet50
14     last_conv_layer_name = 'conv5_block3_2_relu'
15
16 # The local path to our target image
17 img_path = '/content/drive/MyDrive/Minicurso SBCAS/base/test/
18 benign/ISIC_0000038.jpg'
19
20 img_array = preprocess_input(get_img_array(img_path, size=img_size
21 ))
22
23 # Remove last layer's softmax
24 path_model.layers[-1].activation = None
25
26 # Print what the top predicted class is
27 preds = path_model.predict(img_array)
28
29 # Generate class activation heatmap
30 heatmap = make_gradcam_heatmap(img_array, path_model,
31     last_conv_layer_name)
32
33 #Display heatmap
34 #plt.matshow(heatmap)
35 #plt.show()
36
37 save_and_display_gradcam(img_path, heatmap)

```

A Figura 3.15 mostra os mapas de calor com as regiões de ativação de duas CNNs (VGG-16 e ResNet50). Nos mapas de ativação indicados na Figura 3.15, os tons vermelhos estão associados às regiões que contribuíram consideravelmente para a classificação final, enquanto as demais cores representam outras regiões contribuíram menos.

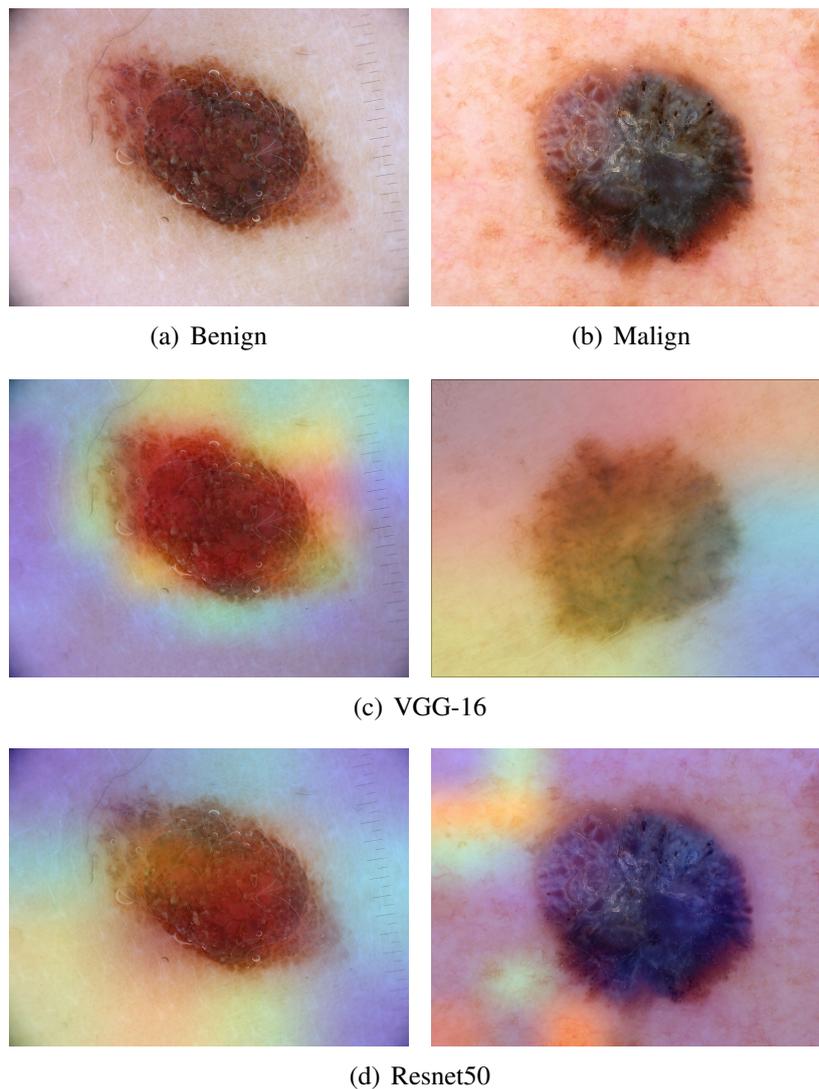


Figura 3.15. Exemplos da aplicação do Grad-CAM.

- LIME: o *Local Interpretable Model-agnostic Explanations* (LIME) é uma técnica de explicabilidade de modelos de aprendizado de máquina que busca fornecer *insights* sobre como esses modelos tomam decisões.

Essa técnica é um “modelo-agnóstico”, o que significa que pode ser aplicado a qualquer tipo de modelo, desde que haja uma função de predição disponível. Ele usa uma abordagem de interpretabilidade local, que explora as decisões tomadas por um modelo em relação a instâncias específicas de dados.

O LIME produz explicações em termos de recursos (*features*) relevantes para uma instância específica, o que ajuda os usuários a entender o motivo pelo qual o modelo tomou uma decisão. O LIME é uma técnica útil para ajudar a garantir a transparência e a responsabilidade em sistemas baseados em aprendizado de máquina. A aplicação do lime pode ser descrita pelo código abaixo.

```
1 pip install lime
```

```

1 import lime
2 from lime import lime_image
3 from skimage.segmentation import mark_boundaries
4 from keras.applications.imagenet_utils import decode_predictions
5 import os
6 from skimage.io import imread
7 import matplotlib.pyplot as plt
8
9
10 %matplotlib inline
11
12
13 import numpy as np
14 from keras.applications import inception_v3 as inc_net
15
16
17 def transform_img_fn(path_list):
18     out = []
19     for img_path in path_list:
20         img = keras.utils.load_img(img_path, target_size=(299,
21 299))
22         x = keras.utils.img_to_array(img)
23         x = np.expand_dims(x, axis=0)
24         x = inc_net.preprocess_input(x)
25         out.append(x)
26     return np.vstack(out)
27
28 images = transform_img_fn([os.path.join(img_path)])
29
30
31 preds = path_model.predict(images)
32
33
34
35
36 %load_ext autoreload
37 %autoreload 2
38 import os, sys
39 try:
40     import lime
41 except:
42     sys.path.append(os.path.join('../', '../')) # add the current
43     directory
44     import lime
45 from lime import lime_image
46 explainer = lime_image.LimeImageExplainer()
47
48
49
50 explanation = explainer.explain_instance(images[0].astype('double'
51 ), path_model.predict, top_labels=5, hide_color=0, num_samples
52 =10)
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100
101
102
103
104
105
106
107
108
109
110
111
112
113
114
115
116
117
118
119
120
121
122
123
124
125
126
127
128
129
130
131
132
133
134
135
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170
171
172
173
174
175
176
177
178
179
180
181
182
183
184
185
186
187
188
189
190
191
192
193
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
231
232
233
234
235
236
237
238
239
240
241
242
243
244
245
246
247
248
249
250
251
252
253
254
255
256
257
258
259
260
261
262
263
264
265
266
267
268
269
270
271
272
273
274
275
276
277
278
279
280
281
282
283
284
285
286
287
288
289
290
291
292
293
294
295
296
297
298
299
300
301
302
303
304
305
306
307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327
328
329
330
331
332
333
334
335
336
337
338
339
340
341
342
343
344
345
346
347
348
349
350
351
352
353
354
355
356
357
358
359
360
361
362
363
364
365
366
367
368
369
370
371
372
373
374
375
376
377
378
379
380
381
382
383
384
385
386
387
388
389
390
391
392
393
394
395
396
397
398
399
400
401
402
403
404
405
406
407
408
409
410
411
412
413
414
415
416
417
418
419
420
421
422
423
424
425
426
427
428
429
430
431
432
433
434
435
436
437
438
439
440
441
442
443
444
445
446
447
448
449
450
451
452
453
454
455
456
457
458
459
460
461
462
463
464
465
466
467
468
469
470
471
472
473
474
475
476
477
478
479
480
481
482
483
484
485
486
487
488
489
490
491
492
493
494
495
496
497
498
499
500
501
502
503
504
505
506
507
508
509
510
511
512
513
514
515
516
517
518
519
520
521
522
523
524
525
526
527
528
529
530
531
532
533
534
535
536
537
538
539
540
541
542
543
544
545
546
547
548
549
550
551
552
553
554
555
556
557
558
559
560
561
562
563
564
565
566
567
568
569
570
571
572
573
574
575
576
577
578
579
580
581
582
583
584
585
586
587
588
589
590
591
592
593
594
595
596
597
598
599
600
601
602
603
604
605
606
607
608
609
610
611
612
613
614
615
616
617
618
619
620
621
622
623
624
625
626
627
628
629
630
631
632
633
634
635
636
637
638
639
640
641
642
643
644
645
646
647
648
649
650
651
652
653
654
655
656
657
658
659
660
661
662
663
664
665
666
667
668
669
670
671
672
673
674
675
676
677
678
679
680
681
682
683
684
685
686
687
688
689
690
691
692
693
694
695
696
697
698
699
700
701
702
703
704
705
706
707
708
709
710
711
712
713
714
715
716
717
718
719
720
721
722
723
724
725
726
727
728
729
730
731
732
733
734
735
736
737
738
739
740
741
742
743
744
745
746
747
748
749
750
751
752
753
754
755
756
757
758
759
760
761
762
763
764
765
766
767
768
769
770
771
772
773
774
775
776
777
778
779
780
781
782
783
784
785
786
787
788
789
790
791
792
793
794
795
796
797
798
799
800
801
802
803
804
805
806
807
808
809
810
811
812
813
814
815
816
817
818
819
820
821
822
823
824
825
826
827
828
829
830
831
832
833
834
835
836
837
838
839
840
841
842
843
844
845
846
847
848
849
850
851
852
853
854
855
856
857
858
859
860
861
862
863
864
865
866
867
868
869
870
871
872
873
874
875
876
877
878
879
880
881
882
883
884
885
886
887
888
889
890
891
892
893
894
895
896
897
898
899
900
901
902
903
904
905
906
907
908
909
910
911
912
913
914
915
916
917
918
919
920
921
922
923
924
925
926
927
928
929
930
931
932
933
934
935
936
937
938
939
940
941
942
943
944
945
946
947
948
949
950
951
952
953
954
955
956
957
958
959
960
961
962
963
964
965
966
967
968
969
970
971
972
973
974
975
976
977
978
979
980
981
982
983
984
985
986
987
988
989
990
991
992
993
994
995
996
997
998
999
1000

```

```

3 temp, mask = explanation.get_image_and_mask(explanation.top_labels
      [0], positive_only=False, num_features=100, hide_rest=False)
4 plt.imshow(mark_boundaries(temp / 2 + 0.5, mask))

```

A Figura 3.16 mostra os mapas gerados pelo lime, as regiões marcadas em verde contribuíram significativamente para a classificação, enquanto em oposição as regiões em vermelho contribuem negativamente.

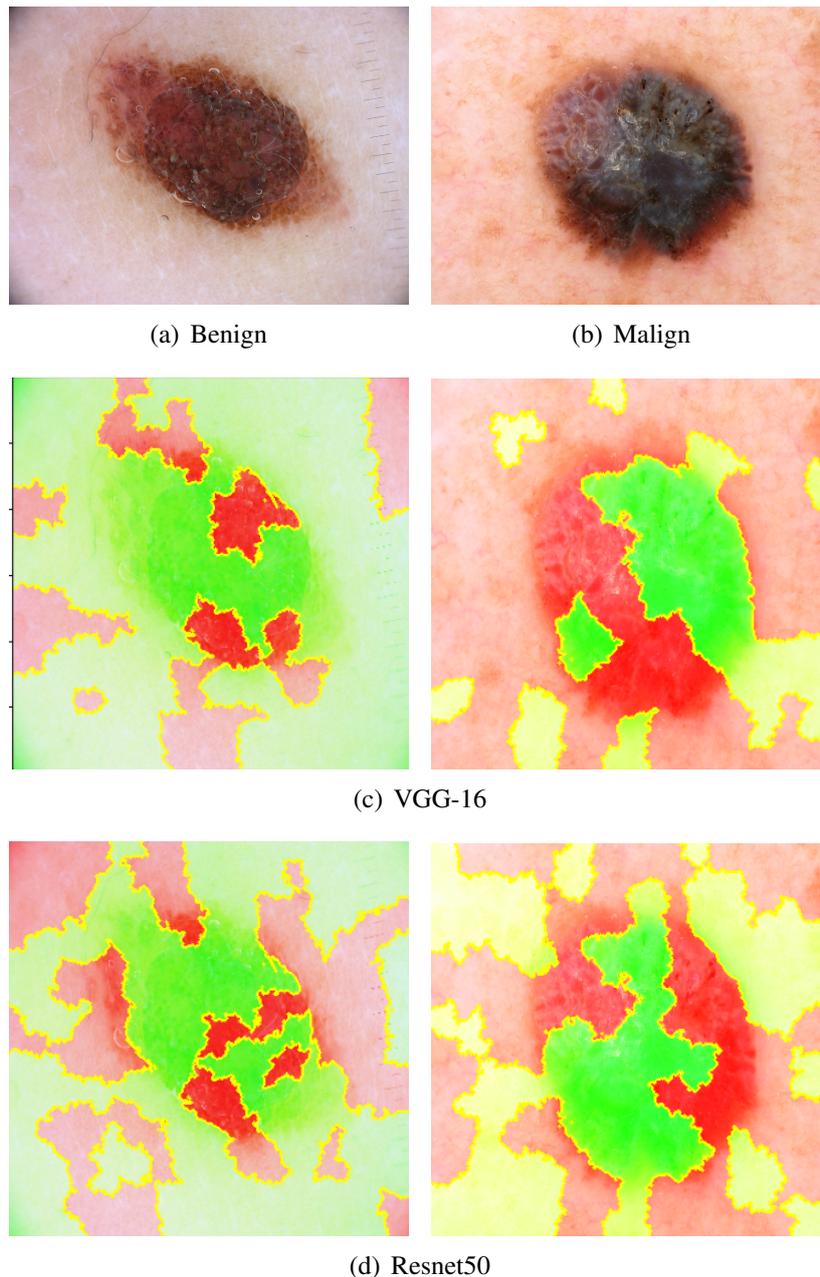


Figura 3.16. Exemplos da aplicação do LIME.

- t-SNE: nessa seção será trabalhada a explicabilidade nos espaços de características com o algoritmo *t-Distributed Stochastic Neighbor Embedding* (t-SNE) [van der Maaten and Hinton 2008].

O t-SNE é um algoritmo que permite a redução e visualização de dados de altas dimensões. Por meio dessa técnica, é possível representar características extraídas por CNNs em alto nível, permitindo criar novas representações que justifiquem como o aprendizado ocorreu e quais características são cruciais para a separação das classes utilizando um classificador linear. Sua implementação é apresentada pelo seguinte código.

```

1 from __future__ import print_function
2 import time
3 import numpy as np
4 import pandas as pd
5
6 import matplotlib.pyplot as plt
7 import seaborn as sns
8 from mpl_toolkits.mplot3d import Axes3D
9
10 import keras
11 from keras.applications.vgg16 import preprocess_input
12 from keras_preprocessing import image
13 from keras.models import Model, Sequential
14 from keras.layers import Input, Dense, Dropout, Flatten,
    BatchNormalization
15
16 import os
17 import glob
18
19 import sklearn
20 from sklearn.svm import SVC
21 from sklearn import svm
22 from sklearn.ensemble import RandomForestClassifier as rdf
23 from sklearn import metrics
24 from sklearn.decomposition import PCA
25 from sklearn.model_selection import train_test_split
26 from sklearn.model_selection import KFold
27 from sklearn.metrics import precision_score, f1_score,
    recall_score, cohen_kappa_score, confusion_matrix
28 from sklearn.ensemble import RandomForestClassifier
29 from sklearn.model_selection import cross_validate,
    cross_val_predict
30 from sklearn.manifold import TSNE
31
32 vgg16_model = keras.applications.vgg16.VGG16(include_top=True,
    weights='imagenet')
33 model = Sequential()
34
35 for layer in vgg16_model.layers[:-1]:
36     model.add(layer)
37
38 def extracao_vetor_CNNs(files, classe, model):
39     print('Iniciando extracao...')
40     modelo = 1
41     # Selecionando a VGG-16 como descritor
42     # Definindo a camada a ser extraída, a "fc2" e a ultima camada
    totalmente conectada antes da ativacao.
43     layer_name = 'fc2'

```

```

44 tamanho = (224, 224)
45 print('Modelo VGG-16 escolhido...')
46 # model.summary()
47 # Definindo a matriz que ira conter as caracteristicas
   extraidas
48 feature_list = []
49 # Para todas as imagens definidas no diretorio, faca:
50 for f1 in files:
51     print(f1)
52     # Carregando imagem original e redimensionando para 224
   x224
53     img = image.load_img(f1, target_size=tamanho)
54
55     # Transformando a imagem um array
56     img_data = image.img_to_array(img)
57     img_data = np.expand_dims(img_data, axis=0)
58     img_data = preprocess_input(img_data)
59
60     # A partir do modelo, definimos que a saida da CNN e a
   camada objetivo (fc2) utilizando model.get_layer.output
61     #modelo_camada_intermediaria = Model(inputs=model.input,
62     #                                     outputs=model.
   get_layer('fc1').output)
63
64     # Passando a imagem de entrada atraves do modelo pre-
   treinado
65     saida_atual = model.predict(img_data)
66     print(saida_atual.shape)
67
68     # Concatenando a classe ao vetor extraido
69     saida_atual = np.append(saida_atual, classe)
70
71     # Concatenando o vetor da imagem i extraida na matriz de
   caracteristicas final
72     feature_list.append(saida_atual.flatten())
73
74     print('Extracao concluida!! A matriz de caracteristicas foi
   construida!!')
75     return feature_list
76
77
78 def construcacao_matriz(dir_doente, dir_saudavel, model):
79     # Carregando os diretorios das imagens doentes
80     data_path_doente = os.path.join(dir_doente, '*')
81     files_doente = glob.glob(data_path_doente)
82     # Definindo a classe doente como 1
83     classe_doente = 1
84     # Extraindo a matriz de caracteristicas
85     matriz_doente = np.array(extracao_vetor_CNNS(files_doente,
   classe_doente, model))
86
87     # Carregando os diretorios das imagens saudaveis
88     data_path_saudavel = os.path.join(dir_saudavel, '*')
89     files_saudavel = glob.glob(data_path_saudavel)
90     # Definindo a classe saudavel como 0

```

```

91     classe_saudavel = 0
92     # Extraíndo a matriz de características
93     matriz_saudavel = np.array(extracao_vetor_CNNS(files_saudavel,
94         classe_saudavel, model))
95
96     # Concatenando as matrizes doente e saudavel.
97     matriz_final = np.concatenate((matriz_doente, matriz_saudavel)
98         , axis=0)
99
100    return matriz_final
101
102 classe_0_teste = 'path\\'
103 classe_1_teste = 'path\\'
104
105 vetor_teste = construcacao_matriz(classe_0_teste, classe_1_teste,
106     model)
107
108 classe_0_treino = 'path\\'
109 classe_1_treino = 'path\\'
110
111 vetor_treino = construcacao_matriz(classe_0_treino, classe_1_treino
112     , model)
113
114 ## T-SNE
115
116 # Carregando as 1000 primeiras características de cada imagem
117 pca = PCA(n_components=100)
118
119 data_X = vetor_treino[:,0:4096]
120 #data_X = pca.fit_transform(data_X)
121
122 data_Y = vetor_teste[:,0:4096]
123
124 # Carregando as labels de cada imagem
125 y = vetor_teste[:,4096]
126 x = vetor_treino[:,4096]
127
128 # Executando o tsne
129 from sklearn.manifold import TSNE
130 tsne = TSNE(n_components=2, random_state=0, perplexity=50.0)
131
132 tsne_obj= tsne.fit_transform(data_Y)
133
134 a = numpy.asarray(tsne_obj)
135 numpy.savetxt("VGG-16_TSNE.csv", a, delimiter=",")
136
137 tsne_df = pd.DataFrame({'X':tsne_obj[:,0],
138     'Y':tsne_obj[:,1],
139     'Classificacao':y})
140 tsne_df.head()
141
142 #classificador_SVM = svm.SVC(kernel='linear', gamma=0.01, C = 1)
143 classificador_SVM = rdf()
144 classificador_SVM.fit(data_X, x)

```

```

142
143 teste_A = classificador_SVM.predict(data_Y)
144 print(teste_A.shape)
145 print(y.shape)
146 #predito_SVM = cross_validation.cross_val_predict(
147     classificador_SVM, data_X, y, cv=10)
148 print('Experimento A :-----')
149 acuracia_SVM = metrics.accuracy_score(y, teste_A)
150 print('Acc:', acuracia_SVM)
151 precisao_SVM = precision_score(y, teste_A)
152 print('Precisao weighted:', precisao_SVM)
153 kappa_SVM = cohen_kappa_score(y, teste_A)
154 print('Kappa:', kappa_SVM)
155 recall_SVM = recall_score(y, teste_A)
156 print('Recall weighted:', recall_SVM)
157 cm = confusion_matrix(y, teste_A)
158 print(cm)
159
160 print('Experimento B:-----')
161 SVM_B = svm.SVC(kernel='linear', gamma=0.01, C = 1)
162 teste_B = cross_val_predict(SVM_B, data_Y, y, cv=10)
163 print('-----SVM-----')
164 acuracia_SVM = metrics.accuracy_score(y, teste_B)
165 print('Acc:', acuracia_SVM)
166 precisao_SVM = precision_score(y, teste_B)
167 print('Precisao weighted:', precisao_SVM)
168 kappa_SVM = cohen_kappa_score(y, teste_B)
169 print('Kappa:', kappa_SVM)
170 recall_SVM = recall_score(y, teste_B)
171 print('Recall weighted:', recall_SVM)
172 cm = confusion_matrix(y, teste_B)
173 print(cm)
174
175 from mlxtend.plotting import plot_decision_regions
176 import mlxtend
177 import numpy as np
178 import matplotlib.pyplot as plt
179 from sklearn import datasets, svm
180
181 y_t = np.int64(y)
182
183 clf = svm.SVC(kernel = 'linear', gamma=0.01, C = 1,
184     decision_function_shape='ovo')
185 clf.fit(tsne_obj, y_t)
186
187 # Plot Decision Region using mlxtend's awesome plotting function
188 plot_decision_regions(X=tsne_obj,
189     y=y_t,
190     clf=clf,
191     legend=2)
192
193 # Update plot object with X/Y axis labels and Figure Title
194 plt.xlabel('Análise de características', size=14)
195 plt.ylabel(X.columns[1], size=14)

```

```
195 plt.title('SVM Decision Region Boundary', size=16)  
196 plt.savefig('TSNE_VGG_SAMPLE.png')
```

3.5. Conclusão

O trabalho demonstrou a definição da base de imagens, bem como seu pré-processamento. Além disso, abordou a organização e criação de duas CNN a partir do conjunto ImageNet. Essas CNN's foram treinadas e em seguida testadas com a finalidade de verificar a quantidade de predições realizadas corretamente. Após obter as predições, aplica-se a explicabilidade nas imagens preditas corretamente.

Conforme a saída da técnica de explicabilidade adotada, pode-se entender quais características influenciaram no processo de classificação das CNN's, ou seja, é possível justificar a tomada de decisão. Logo, a utilização da explicabilidade traz um grande benefício para o meio científico e conseqüentemente uma maior aceitação em trabalhos clínicos, pois aumenta a distância do padrão “caixa-preta”, no qual o porquê da saída da CNN é desconhecido.

Ainda, um direcionamento futuro para trabalhar com explicabilidade seria buscar otimizar o desempenho das CNNs por meio de mudanças de parâmetros, utilização de pré-processamento das imagens, técnicas de aumento de dados com transformações de espaço de cores ou transformações baseadas em *Deep Learning*. Outro ponto relevante seria a aplicação de métodos intrínsecos sobre as imagens para uma explicação mais transparente.

Referências

- [Acharya and Ray 2005] Acharya, T. and Ray, A. K. (2005). *Image processing: principles and applications*. John Wiley & Sons.
- [Bejnordi et al. 2018] Bejnordi, B. E., Mullooly, M., Pfeiffer, R. M., Fan, S., Vacek, P. M., Weaver, D. L., Herschorn, S., Brinton, L. A., van Ginneken, B., Karssemeijer, N., Beck, A. H., Gierach, G. L., van der Laak, J. A. W. M., and Sherman, M. E. (2018). Using deep convolutional neural networks to identify and classify tumor-associated stroma in diagnostic breast biopsies. *Modern Pathology*, 31:1502–1512.
- [Chen et al. 2019] Chen, C., Li, O., Tao, D., Barnett, A., Rudin, C., and Su, J. K. (2019). This looks like that: deep learning for interpretable image recognition. *Advances in neural information processing systems*, 32.
- [Chollet 2017] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *2017 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, Honolulu, HI, USA, July 21-26, 2017*, pages 1800–1807.
- [Deng et al. 2009] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, pages 248–255. Ieee.
- [Devlin et al. 2018] Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- [Dundas and Chik 2011] Dundas, J. and Chik, D. (2011). Implementing human-like intuition mechanism in artificial intelligence. *arXiv preprint arXiv:1106.5917*.
- [Erhan et al. 2009] Erhan, D., Bengio, Y., Courville, A., and Vincent, P. (2009). Visualizing higher-layer features of a deep network. *University of Montreal*, 1341(3):1.
- [Fukushima 1988] Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural Networks*, 1(2):119 – 130.
- [Furat et al. 2023] Furat, O., Kirstein, T., Leißner, T., Bachmann, K., Gutzmer, J., Peuker, U. A., and Schmidt, V. (2023). Multidimensional characterization of particle morphology and mineralogical composition using ct data and r-vine copulas.
- [Gomes and Velho 1997] Gomes, J. and Velho, L. (1997). *Image processing for computer graphics*. Springer Science & Business Media.
- [Gonzalez et al. 2002] Gonzalez, R. C., Woods, R. E., et al. (2002). Digital image processing.
- [Goyal et al. 2017] Goyal, Y., Khot, T., Summers-Stay, D., Batra, D., and Parikh, D. (2017). Making the v in vqa matter: Elevating the role of image understanding in visual question answering.

- [Guo et al. 2017] Guo, Z., Chen, Q., Wu, G., Xu, Y., Shibasaki, R., and Shao, X. (2017). Village building identification based on ensemble convolutional neural networks. *Sensors*, 17:2487.
- [Gupta et al. 2018] Gupta, A., Harrison, P., Wieslander, H., Pielawski, N., Kartasalo, K., Partel, G., Solorzano, L., Suveer, A., Klemm, A., Spjuth, O., Sintorn, I.-M., and Wählby, C. (2018). Deep learning in image cytometry: A review. *Cytometry Part A*, 95.
- [Gutman et al. 2016] Gutman, D., Codella, N. C. F., Celebi, M. E., Helba, B., Marchetti, M. A., Mishra, N. K., and Halpern, A. (2016). Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (ISBI) 2016, hosted by the international skin imaging collaboration (ISIC). *arXiv*.
- [Hachilif et al. 2019] Hachilif, R., Baghdadi, R., and Benhamida, F. (2019). *Graduation Thesis Implementing and Optimizing Neural Networks using Tiramisu*. PhD thesis.
- [Haykin 2007] Haykin, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.
- [He et al. 2016] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 770–778. IEEE Computer Society.
- [Hou and Zhou 2018] Hou, B.-J. and Zhou, Z.-H. (2018). Learning with interpretable structure from rnn. *arXiv preprint arXiv:1810.10708*.
- [Hu et al. 2018] Hu, J., Shen, L., and Sun, G. (2018). Squeeze-and-excitation networks. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 7132–7141.
- [Huang et al. 2017] Huang, G., Liu, Z., v. d. Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 2261–2269.
- [Jia et al. 2014] Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S., and Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. In *Proceedings of the 22Nd ACM International Conference on Multimedia, MM '14*, pages 675–678.
- [Krizhevsky et al. 2012] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc.
- [Landis and Koch 1977] Landis, J. R. and Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1):159–174.

- [Lapuschkin et al. 2016] Lapuschkin, S., Binder, A., Montavon, G., Müller, K.-R., and Samek, W. (2016). Analyzing classifiers: Fisher vectors and deep neural networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2912–2920.
- [Lecun et al. 1998] Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- [Lecun et al. 1998] Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. In *Proceedings of the IEEE*, pages 2278–2324.
- [Li et al. 2016] Li, J., Monroe, W., and Jurafsky, D. (2016). Understanding neural networks through representation erasure. *arXiv preprint arXiv:1612.08220*.
- [Li et al. 2017] Li, J., Monroe, W., and Jurafsky, D. (2017). Understanding neural networks through representation erasure.
- [Lundberg and Lee 2017] Lundberg, S. and Lee, S.-I. (2017). A unified approach to interpreting model predictions.
- [Luong et al. 2015] Luong, M.-T., Pham, H., and Manning, C. D. (2015). Effective approaches to attention-based neural machine translation. *arXiv preprint arXiv:1508.04025*.
- [Murdoch and Szlam 2017] Murdoch, W. and Szlam, A. (2017). Automatic rule extraction from long short term memory networks, [in:] international conference on learning representations. *Toulon, France, April*, pages 23–26.
- [Pacheco and Pereira 2018] Pacheco, C. A. R. and Pereira, N. S. (2018). Deep learning conceitos e utilização nas diversas áreas do conhecimento. *Revista Ada Lovelace*, 2:34–49.
- [Ramzan et al. 2019] Ramzan, F., Khan, M. U., Rehmat, A., Iqbal, S., Saba, T., Rehman, A., and Mehmood, Z. (2019). A deep learning approach for automated diagnosis and multi-class classification of alzheimer’s disease stages using resting-state fmri and residual neural networks. *Journal of Medical Systems*, 44.
- [Rezende 2003] Rezende, S. O. (2003). *Sistemas inteligentes: fundamentos e aplicações*. Editora Manole Ltda.
- [Ribeiro et al. 2016a] Ribeiro, M. T., Singh, S., and Guestrin, C. (2016a). "why should i trust you?" explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pages 1135–1144.
- [Ribeiro et al. 2016b] Ribeiro, M. T., Singh, S., and Guestrin, C. (2016b). Model-agnostic interpretability of machine learning. *arXiv preprint arXiv:1606.05386*.

- [Ronneberger et al. 2015] Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597.
- [Russakovsky et al. 2015] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*, 115(3):211–252.
- [Selvaraju et al. 2017] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision*, pages 618–626.
- [Shaees et al. 2020] Shaees, S., Naeem, M. R., Naeem, H., Syed, H., Arslan, M., and Aldabbas, H. (2020). Facial emotion recognition using transfer learning.
- [Shorten and Khoshgoftaar 2019] Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1):60.
- [Simonyan and Zisserman 2014] Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- [Sophiya and Jothilakshmi 2018] Sophiya, E. and Jothilakshmi, S. (2018). Large scale data based audio scene classification. *International Journal of Speech Technology*, 21:825–836.
- [Sundararajan et al. 2016] Sundararajan, M., Taly, A., and Yan, Q. (2016). Gradients of counterfactuals. *arXiv preprint arXiv:1611.02639*.
- [Sundararajan et al. 2017] Sundararajan, M., Taly, A., and Yan, Q. (2017). Axiomatic attribution for deep networks. In *International conference on machine learning*, pages 3319–3328. PMLR.
- [Szegedy et al. 2016] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *2016 IEEE Conference on Computer Vision and Pattern Recognition CVPR 2016, Las Vegas, NV, USA, June 27-30, 2016*, pages 2818–2826.
- [Szegedy et al. 2015] Szegedy, C., Wei Liu, Yangqing Jia, Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going deeper with convolutions. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1–9.
- [Taylor and Nitschke 2018] Taylor, L. and Nitschke, G. (2018). Improving deep learning with generic data augmentation. In *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, pages 1542–1547. IEEE.
- [Uchiyama et al. 2023] Uchiyama, T., Sogi, N., Niinuma, K., and Fukui, K. (2023). Visually explaining 3d-cnn predictions for video classification with an adaptive occlusion sensitivity analysis. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, pages 1513–1522.

- [van der Maaten and Hinton 2008] van der Maaten, L. and Hinton, G. (2008). Visualizing data using t-SNE. *Journal of Machine Learning Research*, 9:2579–2605.
- [Xie et al. 2020] Xie, N., Ras, G., van Gerven, M., and Doran, D. (2020). Explainable deep learning: A field guide for the uninitiated. *J. Artif. Intell. Res.*, 73:329–396.
- [Zeiler and Fergus 2014a] Zeiler, M. D. and Fergus, R. (2014a). Visualizing and understanding convolutional networks. In *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13*, pages 818–833. Springer.
- [Zeiler and Fergus 2014b] Zeiler, M. D. and Fergus, R. (2014b). Visualizing and understanding convolutional networks. In *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13*, pages 818–833. Springer.
- [Zeiler et al. 2011] Zeiler, M. D., Taylor, G. W., and Fergus, R. (2011). Adaptive deconvolutional networks for mid and high level feature learning. In *2011 international conference on computer vision*, pages 2018–2025. IEEE.
- [Zellers et al. 2019] Zellers, R., Bisk, Y., Farhadi, A., and Choi, Y. (2019). From recognition to cognition: Visual commonsense reasoning. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 6720–6731.
- [Zhou et al. 2016] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., and Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2921–2929.

Capítulo

4

Padrões e Soluções para Armazenamento, Compartilhamento e Estruturação de Dados em Saúde Digital: Privacidade, Integração e Desafios

Nicollas R. de Oliveira (UFF), Yago de R. dos Santos (UFF),
Ana Carolina R. Mendes (UFF), Guilherme N. N. Barbosa (UFF),
Marcela T. de Oliveira (TU Delft), Rafael Valle (RNP),
Dianne S. V. Medeiros (UFF), Diogo M. F. Mattos (UFF)

Resumo

A pandemia de COVID-19 enfatizou a necessidade de serviços de saúde ágeis com trocas de informações confiáveis e seguras. O compartilhamento adequado, privado e seguro de Registros Médicos Eletrônicos (Electronic Medical Records – EMRs) é um desafio devido à diversidade de formatos de dados e à fragmentação dos registros em diversos silos de dados. Registros fragmentados atrapalham e atrasam a coordenação entre equipes de saúde, podendo resultar em erros médicos e atrasar o tratamento dos pacientes. O acesso seguro e padronizado aos EMRs tende a melhorar o atendimento ao paciente. Contudo, sistemas de EMR centralizados apresentam riscos à privacidade, enquanto a diversidade de formatos de dados dificulta a interoperabilidade. A tecnologia de cadeia de blocos (blockchain) oferece armazenamento descentralizado, integridade de dados e controle de acesso, eliminando intermediários e aumentando a eficiência. Este capítulo explora padrões de EMR, desafios de segurança e soluções baseadas em cadeia de blocos para interoperabilidade e compartilhamento seguro de dados na área da saúde.

4.1. Introdução

O setor da saúde é um exemplo típico de onde o compartilhamento de dados pessoais entre organizações é essencial e o acesso a esses dados é intrinsecamente distribuído. Os profissionais de saúde de várias organizações precisam analisar os dados dos pacientes para realizar suas tarefas, mas normalmente esses dados estão armazenados em silos localizados em diversos locais e em formatos distintos, dificultando o compartilhamento.

Este capítulo foi realizado com recursos do CNPq, CAPES, RNP, FAPERJ, FAPESP (2018/23062-5) e Prefeitura de Niterói/FEC/UFF (Edital PDPA 2020).

Assim, a complexidade do sistema médico impede que todo o histórico médico do paciente seja facilmente acessado quando necessário. Dessa forma, muita informação é perdida ou exaustivamente repetida, dificultando o diagnóstico e o tratamento do paciente e prejudicando a jornada do paciente.

De acordo com uma pesquisa realizada no Hospital American Johns Hopkins, os erros médicos são a terceira principal causa de morte nos Estados Unidos e a maioria dos erros decorre de problemas sistêmicos, incluindo cuidados mal coordenados [Makary e Daniel, 2016]. O desafio da coordenação dos cuidados aos pacientes pode ser mitigado através do compartilhamento correto e seguro dos dados desses pacientes, permitindo que as equipes possam acessar o histórico completo de saúde do paciente, inclusive para promover o diagnóstico precoce, melhorando a efetividade do tratamento. Ambientes de saúde informatizados facilitam o acesso a esses dados distribuídos, pois os dados do paciente são armazenados sob a forma de Registros Médicos Eletrônicos (*Electronic Medical Records* – EMRs) padronizados. Os EMRs contêm informações pessoais privadas sobre o paciente, incluindo diagnósticos e tratamentos, e normalmente estão distribuídos entre hospitais e clínicas que já trataram o paciente pelo menos uma vez durante sua vida. Os EMRs possibilitam monitorar e acessar de forma rápida e padronizada os dados dos pacientes e permitem integrar o cuidado ao paciente entre os membros da equipe médica e de outras equipes e estabelecimentos de saúde. Assim, possibilita-se que diferentes níveis de atendimento acessem às informações médicas relevantes de cada paciente. Por um lado, o compartilhamento dessas informações é benéfico para o paciente, visto que auxilia a equipe a obter um diagnóstico mais assertivo e, portanto, um tratamento mais adequado para o paciente. Por outro lado, as informações privadas do paciente armazenadas nos EMRs são altamente confidenciais e sensíveis. Essas informações são frequentemente compartilhadas, sem o consentimento do paciente, entre entidades não confiáveis, como profissionais de saúde, farmácias, familiares de pacientes e outros médicos [Dubovitskaya et al., 2017]. Esse compartilhamento é realizado, por exemplo, no momento do encaminhamento de um paciente de uma clínica para um hospital que possua mais recursos para o seu tratamento. Quando possível, os dados do paciente são compartilhados por meio de sistemas médicos institucionais seguros. Contudo, por simplicidade e imediatismo, os dados também são compartilhados por meios de comunicação não institucionalizados e, normalmente, inseguros.

No contexto pandêmico, ressaltou-se a necessidade de tornar mais ágeis os atendimentos e o fluxo de troca de informações entre pacientes, médicos e organizações de saúde. Diante disso, registros dos pacientes adquiriram uma maior importância em termos de saúde pública [Stoeger e Schmidhuber, 2020] e dados sobre diagnósticos e medicamentos prescritos podem ser utilizados para identificar pessoas em grupos de risco da COVID-19, por exemplo. A maior disponibilidade de dados dos pacientes em formato eletrônico é de grande relevância para a tomada de decisão e continuidade do cuidado nos setores público e privado, principalmente com troca de informações entre as duas esferas. Dados que indiquem precocemente focos de surtos de doenças são importantes para coordenar ações de políticas de saúde pública para prevenção em âmbito nacional e de forma eficiente. Os benefícios do compartilhamento eficiente estendem-se aos pacientes também, uma vez que permite que os pacientes acessem suas próprias informações a qualquer momento, tais como resultados de exames laboratoriais e de imagens, sendo

possível realizar a portabilidade desses dados para outro médico ou organização de saúde. A comunicação eficiente e automatizada entre os pacientes e as equipes médicas [Hurst et al., 2022] universaliza o acesso aos dados promovendo transparência e um aumento da satisfação do paciente.

A importância e a relevância da disponibilidade de dados são crescentes e essa disponibilidade está sendo implementada em muitos estabelecimentos. Em 2019, por exemplo, verificou-se um aumento na disponibilidade de informações do paciente em formato eletrônico. Entre os principais aumentos em relação a 2018 estão: dados cadastrais dos pacientes (89% contra 79%); principais motivos que levaram o paciente à consulta (64% contra 50%) e admissão, transferência e alta (56% contra 43%) [Cetic.br, 2020]. Quanto às funcionalidades do sistema eletrônico, o destaque é o aumento de sua disponibilização nos estabelecimentos públicos nos últimos anos, principalmente em relação a listar todos os resultados de exames laboratoriais (de 17%, em 2016, para 41%, em 2019), listar todos os pacientes que usam uma medicação (de 18%, em 2016, para 40%, em 2019) e realizar prescrição médica (de 29% para 51%) [Cetic.br, 2020]. Esses aumentos podem indicar uma evolução no nível e na complexidade dos sistemas eletrônicos adotados, que resultam em menor fragmentação na prestação do cuidado, favorecendo a qualidade e eficiência, e reduzindo lacunas no atendimento [Janett e Yeracaris, 2020]. No entanto, avanços na adesão de práticas de digitalização de dados e o consequente aumento significativo nos dados sensíveis gerados, expõe diversos desafios a serem abordados pelos sistemas.

Atualmente, os sistemas de EMR baseiam-se majoritariamente em arquiteturas cliente-servidor centralizadas, nas quais uma autoridade central possui acesso completo ao sistema. Todavia, essa arquitetura apresenta alguns desafios relacionados à privacidade e à segurança. Vulnerabilidades no sistema podem resultar em falhas e criar brechas para invasores cibernéticos comprometerem os dados do paciente [Tanwar et al., 2020]. O gerenciamento desses sistemas impõe um desafio para preservar a privacidade enquanto garante a disponibilidade de dados para os agentes autorizados. Paralelamente, os registros são frequentemente mantidos de forma fragmentada em bancos de dados locais, o que impede que um paciente tenha um prontuário eletrônico consolidado [Mettler, 2016].

A padronização do formato de dados é imprescindível para permitir a interoperabilidade na área da saúde. A padronização envolve o estabelecimento de uma linguagem comum para a troca e interpretação de dados médicos, permitindo que sistemas diferentes se comuniquem. No entanto, alcançar essa padronização é um desafio, pois à medida em que o número de aplicativos de saúde, EMRs e dispositivos médicos continuam a se multiplicar, a diversidade de formatos de dados prolifera exponencialmente. Essa fragmentação apresenta desafios significativos para profissionais de saúde, pesquisadores e formuladores de políticas que buscam aproveitar o poder dos dados para melhorar o atendimento ao paciente, avanços em pesquisas e tomadas de decisão baseadas em evidências.

A tecnologia de cadeia de blocos (*blockchain*) apresenta-se como uma tendência para a padronização e interoperabilidade de registros médicos eletrônicos, visando permitir que o EMR seja verificado e registrado por meio de um consenso de pares que participam de uma rede par-a-par, garantindo a execução confiável de políticas de acesso aos dados e, portanto, assegurando integridade dos dados, responsabilidade e não-repúdio [Christidis e Devetsikiotis, 2016]. Em suma, a tecnologia de cadeia de blocos

torna-se naturalmente atrativa no desenvolvimento de aplicações que (i) exigem a contribuição de várias partes interessadas, embora a confiança entre as partes seja complexa de ser fornecida com tecnologias atuais, (ii) carecem de um rastreamento confiável de atividade e confiabilidade de dados e (iii) desejam remover partes intermediárias, aumentando a eficiência geral do sistema [Engelhardt, 2017]. Nesse contexto, o setor de saúde surge como um candidato no qual a tecnologia de cadeia de blocos tem o potencial de desempenhar um papel fundamental, principalmente devido aos seguintes elementos-chave [Siyal et al., 2019, Namasudra et al., 2022]:

- **Descentralização:** não há necessidade de intermediário e o sistema de banco de dados está disponível para qualquer pessoa conectada à rede que possua o nível de acesso necessário. O monitoramento, armazenamento, acesso e atualização de dados podem ser realizados nos diversos sistemas que fazem parte da rede;
- **Transparência:** os dados registrados e armazenados em uma cadeia de blocos são transparentes para os usuários, ou seja, todos os usuários podem visualizar as transações realizadas via cadeia de blocos;
- **Imutabilidade:** os dados armazenados não podem ser modificados, permitindo que os interessados provem com certeza matemática que o fluxo de dados históricos é exato e não modificado [Engelhardt, 2017];
- **Autonomia:** os nós da rede são independentes e autônomos, podendo acessar, transferir, armazenar e atualizar dados com segurança e sem intervenção externa;
- **Anonimato:** a identidade dos participantes é anônima, contribuindo para a privacidade, segurança e confiabilidade do sistema.

Este capítulo apresenta os principais padrões de armazenamento e compartilhamento de registros médicos eletrônicos. Os padrões, desde os tradicionais padrões *Health Level 7 (HL7)* e *Imagem Digital e Comunicações em Medicina (Digital Imaging and Communications in Medicine – DICOM)* até formatos emergentes como *Recursos Rápidos de Interoperabilidade de Assistência Médica (Fast Healthcare Interoperability Resources – FHIR)* e *Registro Eletrônico de Saúde Aberto (Open Electronic Health Record – openEHR)*, são apresentados em domínios de uso específicos, tais como armazenamento, compartilhamento, estrutura e terminologias. São abordados os principais desafios de segurança e privacidade no acesso aos dados médicos, focando mecanismos de controle de acesso disponíveis em plataformas de uso comercial e de código aberto. Esses desafios incluem modelos de dados incompatíveis, terminologia e sistemas de codificação variados, práticas de implementação divergentes, desafios de privacidade e de segurança, e da necessidade de políticas e regulamentos harmonizados entre diferentes domínios de validade dos dados de saúde. O capítulo discute o controle de acesso aos dados médicos e foca propostas que visam o uso da tecnologia de cadeia de blocos para o compartilhamento de dados e gerência de políticas de acesso. O capítulo também apresenta conceitos fundamentais sobre a tecnologia de cadeia de blocos, necessários para o entendimento das propostas que utilizam essa tecnologia. A Figura 4.1 mostra a organização da estrutura

deste capítulo. Aos leitores já familiarizados com os conceitos relacionados à tecnologia de cadeia de blocos, recomenda-se seguir a sequência de seções indicada pelas setas sólidas, sem prejuízo à compreensão do capítulo.

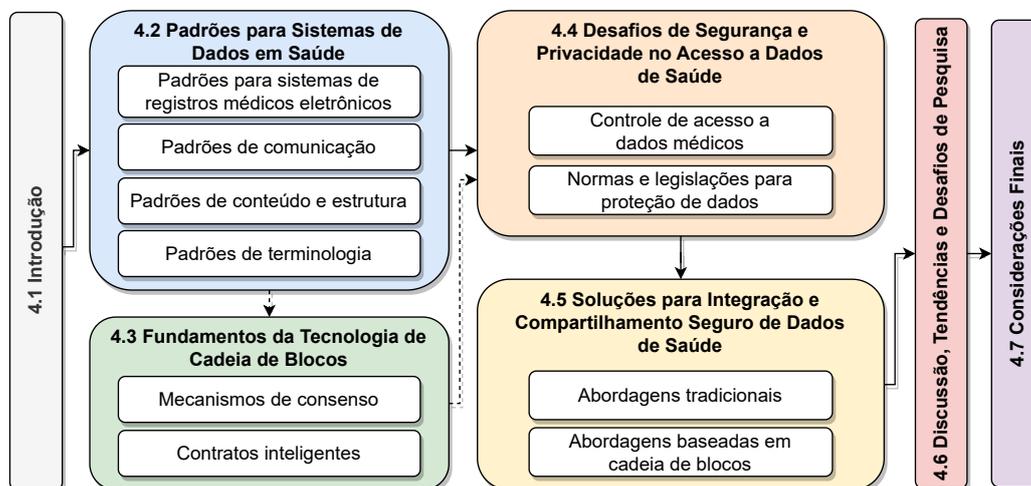


Figura 4.1. Organização da estrutura do minicurso. A sequência de seções indicada pelas setas sólidas é recomendada para os leitores familiarizados com os conceitos básicos relacionados à tecnologia de cadeia de blocos. As setas tracejadas indicam um desvio passando pela Seção 4.3, que apresenta os fundamentos da tecnologia de cadeia de blocos.

4.2. Padrões para Sistemas de Dados em Saúde

Os padrões para sistemas de dados de saúde são formados por conjuntos de normas, especificações e diretrizes que objetivam parametrizar a maneira como as informações clínicas e administrativas são coletadas, armazenadas, processadas e compartilhadas em sistemas de saúde. Além dos padrões para sistemas de saúde, algumas organizações também contribuem para a padronização dos métodos de comunicação entre sistemas, estrutura e normas para armazenamento e representação de dados clínicos, produzindo uma grande variação de padrões para sistemas médicos no mundo. Esta seção aborda padrões de (i) sistemas de registros médicos eletrônicos; (ii) conteúdo e estrutura; (iii) comunicação; e (iv) terminologias. A Tabela 4.1 resume os tipos de padrões abordados nesta seção. No Brasil, existem diversos órgãos responsáveis pela adoção e implementação desses padrões, como o Ministério da Saúde (MS), a Agência Nacional de Saúde Suplementar (ANS), o Conselho Nacional de Secretários de Saúde (CONASS) e o Conselho Nacional de Saúde (CNS). Paralelamente, existem padrões internacionais que são amplamente adotados no desenvolvimento de sistemas em diversos países. O entendimento e seleção desses padrões é fundamental para garantir a interoperabilidade entre os diferentes sistemas de saúde disponíveis no mercado e promover uma assistência à saúde mais eficiente, segura e de qualidade.

4.2.1. Padrões para sistemas de registros médicos eletrônicos

Os padrões de sistemas de registros médicos eletrônicos têm como foco central promover a interoperabilidade entre diferentes sistemas e aplicações de saúde, permi-

Tabela 4.1. Padrões apresentados no capítulo, classificados de acordo com o tipo de padrão e a entidade padronizadora.

Tipo de Padrão	Nome do Padrão	Entidade Padronizadora
Registro médico eletrônico	openEHR (<i>Open Electronic Health Record</i>)	openEHR
Conteúdo e estrutura	CDA (<i>Clinical Document Architecture</i>)	HL7 (<i>Health Level 7</i>)
	FHIR (<i>Fast Healthcare Interoperability Resources</i>)	HL7
	DICOM (<i>Digital Imaging and Communications in Medicine</i>)	NEMA (<i>National Electrical Manufacturers Association</i>)
Comunicação	FHIR	HL7
	HL7 V2 (<i>HL7 Version 2</i>)	HL7
	HL7 V3 (<i>HL7 Version 3</i>)	HL7
	DICOM	NEMA
Terminologia	TUSS (<i>Terminologia Unificada da Saúde Suplementar</i>)	ANS (Agência Nacional de Saúde), AMB (Associação Médica Brasileira), COPISS (Comitê de Padronização das Informações em Saúde Suplementar)
	SNOMED CT (<i>Systematized Nomenclature of Medicine - Clinical Terms</i>)	SNOMED International
	LOINC (<i>Logical Observation Identifiers Names and Codes</i>)	Regenstrief Institute
	ICD (<i>International Classification of Diseases and Related Health Problems</i>)	OMS (Organização Mundial de Saúde)

tindo o compartilhamento e a troca de informações de saúde de forma segura, eficiente e precisa. Tais padrões fundamentam a formulação de modelos de referência alinhados a leis e regulamentações e dedicados ao desenvolvimento de novas aplicações de saúde.

A **openEHR** é uma das organizações responsáveis pela produção e manutenção de especificações e padrões de sistemas de *software* para registros médicos eletrônicos, que recebem o mesmo nome da organização, *openEHR*. Embora proponha modelos para sistemas de saúde, a organização não possui aplicações próprias, tendo como principal contribuição duas arquitetura de referência focadas na integração entre soluções de *software* de saúde², juntamente a especificação de componentes necessários para a implementação da proposta. Além das arquiteturas de referência, a openEHR também especifica os componentes da arquitetura, tanto em relação ao modelo, quanto a aspectos de comunicação, armazenamento, integração e representação dos dados. As especificações *openEHR* utilizam uma abordagem de separação de papéis, atribuindo aos profissionais da saúde a responsabilidade da definição de procedimentos e do primeiro nível de representação dos dados no modelo, que dependem do contexto e são chamados de arquétipos. Paralelamente, designa aos desenvolvedores apenas as funções de integração dos componentes, interface gráfica e serviços de *software* sobre os dados.

A openEHR especifica primeiramente um modelo geral organizado em componentes. Cada componente e suas especificidades são detalhados nas definições do pa-

²Disponível em <https://openehr.org/developers>.

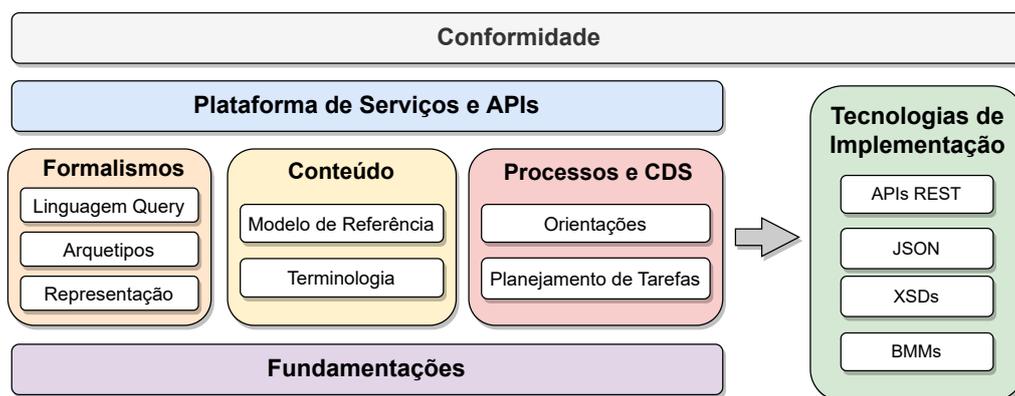


Figura 4.2. Organização dos componentes das especificações dos modelos de referência openEHR.

drão. As duas arquiteturas de referência especificadas pela openEHR são particularizações desse modelo geral. A Figura 4.2 apresenta a organização das especificações em blocos de funcionalidades do modelo geral proposto pela openEHR³. Esses blocos são organizados da seguinte forma:

- **Conformidade:** componente dos critérios de conformidade da aplicação modelo, formando um guia para testes de validação do sistema para licitações, das regras de segurança, testes de integração, API etc. Geralmente aplicado sobre as Especificações de Tecnologias de Implementação (*Implementation Technology Specifications – ITS*);
- **Plataformas de Serviços e Interfaces de Programação de Aplicação (*Application Programming Interfaces – APIs*):** define APIs formais abstratas que determinam as interfaces para a plataforma openEHR;
- **Formalismos:** define formalismos genéricos utilizados tanto para consulta de dados quanto para a definição de dados e procedimentos estáticos, incluindo os arquetipos, que são bibliotecas de classes organizadas em contextos médicos de finalidade pré-definida, porém sendo genéricas o suficiente para a reutilização. Além disso, define a biblioteca de representação das classes internas em Linguagem de Modelagem Unificada (*Unified Modeling Language – UML*) e a Linguagem de Consulta de Arquetipo (*Archetype Query Language – AQL*), que é linguagem *query* de consulta portátil para os arquetipos;
- **Conteúdo:** define modelos de conteúdo primário da plataforma openEHR, incluindo dados demográficos e registros eletrônicos de saúde. Além disso, suporta a terminologia openEHR, juntamente com expressões de outras terminologias.
- **Processos e Suporte à Decisão Clínica (*Clinical Decision Support – CDS*):** define componentes do processo clínico e do CDS, contendo as especificações de planejamento de tarefas e a Linguagem de Definição de Orientações (*Guideline Definition*

³Disponível em https://specifications.openehr.org/releases/BASE/latest/architecture_overview.html.

Language – GDL), ambos usados para desenvolver manuais e orientações de uso organizados por contexto nas aplicações. O componente é voltado aos usuários das aplicações;

- **Fundamentações (*Foundation*):** define tipos primitivos, identificadores e outras classes fundamentais para o funcionamento da openEHR;
- **Especificações de Tecnologias de Implementação (ITS):** define componentes das especificações openEHR que focam na interoperabilidade, como API de comunicação e os diversos tipos de codificação de dados, como o Notação de objeto JavaScript (*JavaScript Object Notation* – JSON) e Definição do Esquema XML (*XML Schema Definitions* – XSDs), além da coleção de representação do modelo utilizado para interfacear com outros sistemas, como o Metamodelo Básico (*Basic Meta-Model* – BMM).

A primeira arquitetura de referência da openEHR é um sistema de informação médico genérico. Essa arquitetura propõe servir de base para o desenvolvimento de aplicações com interoperabilidade garantida. Isso é possível porque o modelo define todos os componentes com base em padrões estabelecidos tanto pela openEHR quanto por outros grupos, como a organização HL7, que define padrões de comunicação e estrutura (Seção 4.2.3 e Seção 4.2.2). A utilização de padrões de comunicação facilitam a troca de dados entre sistemas distintos, definindo formatos, arquitetura de documento, elementos de dados, conteúdo, métodos e APIs usados para alcançar a interoperabilidade.

A segunda arquitetura especificada é referência para um sistema de integração entre outros sistemas, funcionando como um *middleware* de padronização na comunicação e armazenamento de dados. O objetivo central é a integração e padronização de sistemas legados. Dessa forma, para essa arquitetura os esforços são concentrados na definição das APIs entre os diferentes sistemas. As especificações viabilizam a captura, armazenamento, recuperação e compartilhamento de informações clínicas em um formato comum.

Devido à natureza dinâmica dos sistemas de saúde, as especificações openEHR são bem detalhadas, porém as arquiteturas e modelos são genéricos. As especificações se limitam em definir o formalismo do arquétipo necessário para expressar o conteúdo de um domínio, por exemplo, através de *templates* e formulários. Além disso, a openEHR define uma interface de programação de aplicação aberta e uma coleção de modelos estáticos pré-definidos, tais como dados demográficos, procedimentos médicos universais e outros recursos úteis para agilizar o processo de desenvolvimento da maioria dos sistemas que focam atender.

4.2.2. Padrões de conteúdo e estrutura

Os padrões de conteúdo e estrutura determinam a estrutura dos documentos eletrônicos e os tipos de dados que esses documentos devem conter. Os padrões de conteúdo focam especificar quais dados dos pacientes devem ser armazenados e de que forma são relacionados com as etapas do atendimento, acrescentando semântica aos documentos, gerando histórico e informações úteis para o tratamento continuado. Em contrapartida, os padrões de estrutura visam garantir o compartilhamento dos dados entre sistemas e

ampliar a interoperabilidade entre unidades de saúde, sem ditar a forma como esses documentos devem ser transmitidos.

O **CDA** é um tipo de documento geralmente representado em XML que contém dados do paciente e o contexto do atendimento. O CDA é desenvolvido e mantido pela organização HL7, um dos mais importantes grupos de padronização para sistemas médicos. Historicamente, os sistemas médicos que adotaram o CDA não detinham uma definição formal de implementação. Então, surgiram algumas variações para a utilização desse padrão. A HL7 agrupou, documentou, especificou e aprimorou as variações existentes, definindo o padrão de implementação para documentos CDA [HL7, 2015]. O padrão CDA define, então, uma biblioteca de referência para documentos CDA. O CDA é especificado tanto no âmbito de conteúdo e estrutura, quanto para casos de uso nos atendimentos, o que torna o padrão menos genérico. Em decorrência disso, o padrão CDA é organizado em *templates* baseados em casos de uso, tendo atualmente 12 especificações distintas. A implementação é orientada a objetos e contém todas as características desse paradigma, sendo adequado para os casos que necessitam de hierarquia.

O **FHIR** é um arcabouço de padrões de próxima geração criado pela HL7⁴. O FHIR tem como foco a padronização da representação e transação de dados de registros médicos eletrônicos, podendo ser entendido como um conjunto de regras e especificações baseados nas principais funcionalidades dos padrões tradicionais desenvolvidos pela organização HL7, como o HL7 Version 2 (HL7 V2), HL7 Version 3 (HL7 V3) e o CDA. Para representar os dados intercambiáveis, o FHIR utiliza um elemento básico chamado Recurso⁵. Cada Recurso é estruturado seguindo o mesmo formato e pode fornecer informações sobre dados demográficos do paciente, diagnósticos, medicamentos, alergias, planos de cuidados, dentre outras informações. Os Recursos são organizados em seções e precisa conter informações sobre o tipo de Recurso, um identificador do Recurso, os metadados do documento, dados humanamente legíveis em XHTML resumindo o documento, uma referência para o tipo de documento na documentação do sistema e os dados padronizados do paciente ou do exame, como número do registro médico, nome do paciente, plano de saúde, identificação da clínica que está emitindo ou consultando o documento, entre outros. Os Recursos podem ser representados nos formatos XML, JSON e RDF. É válido destacar que o FHIR se diferencia do CDA na representação dos dados por não ter limitação de conteúdo como o CDA, que representa apenas informações clínicas. Além disso, o CDA requer o uso de *templates* para suportar a interoperabilidade. Já no FHIR o conteúdo é interpretado de acordo com a definição do tipo de Recurso, sendo necessário haver a definição do Recurso para que o dado possa ser compartilhado. Ademais, o CDA define a própria sintaxe XML fracamente baseada em HTML. Diferentemente, o FHIR usa um conjunto restrito de XHTML que é mais expressivo do que a marcação usada no CDA. A Figura 4.3 mostra um exemplo de um Recurso do FHIR em XML, destacando as seções de estrutura do documento. A primeira seção, bloco verde, contém o identificador do Recurso e sua versão representada em forma de data e hora da última atualização. Na área de resumo, bloco roxo, são apresentadas as informações do recurso em formato XHTML, dando suporte para leitura direta em um navegador *web*. Na seção de definição, em laranja, é representado o Localizador Uniforme de Recursos (*Uniform Resource Lo-*

⁴Disponível em <https://www.hl7.org/fhir/summary.html>

⁵Disponível em <https://www.hl7.org/fhir/structuredefinition.html>

ator – URL) da especificação do recurso utilizado. Por fim, os dados do registro com o identificador único do paciente MRN *Medical Record Number*, os dados demográficos e resultados de um exame estão representados no último bloco, em azul. Os URLs para as terminologias de referência para o significados dos valores, utilizando rótulos `<system>` e `<value>`, servem de suporte para a padronização e remoção de ambiguidade dos dados representados.

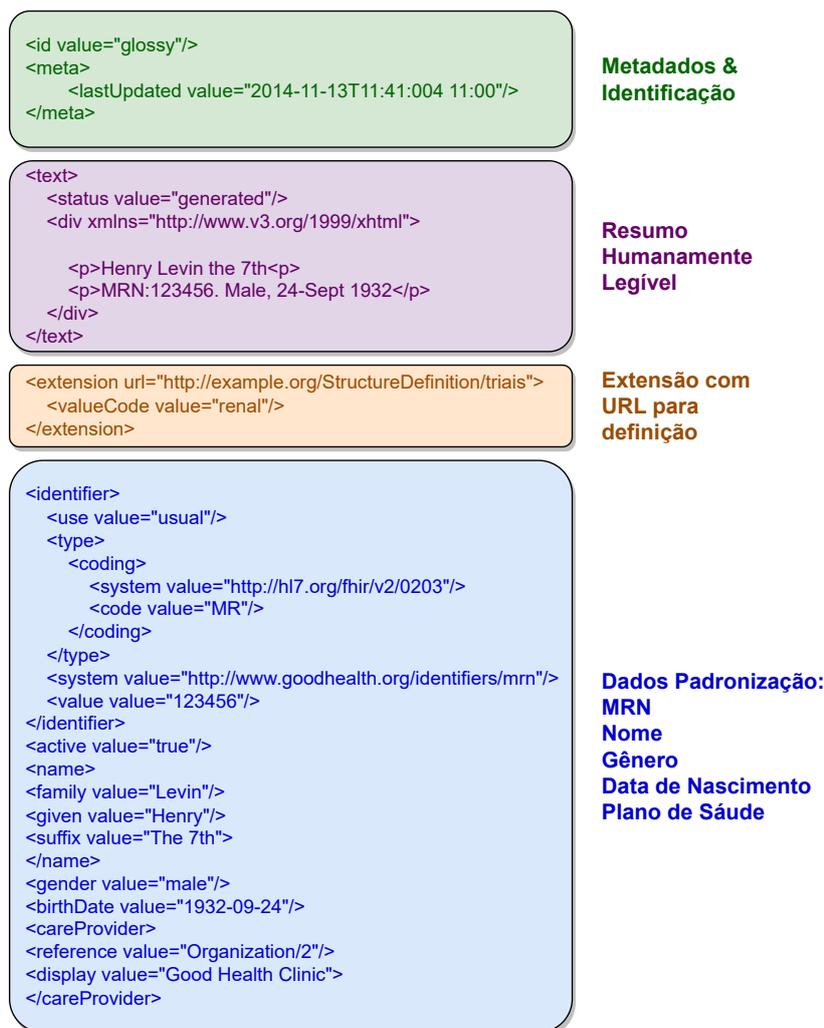


Figura 4.3. Exemplo de um Recurso do FHIR com as seções de estrutura do documento em destaque. A primeira seção, em verde, contém informações sobre metadados e identificação do recurso. A seção seguinte, em roxo, contém o resumo humanamente legível, representado em formato XHTML. A terceira seção, em laranja, contém informações adicionais que não estão na definição básica do tipo de Recurso. A última seção, em azul, contém os dados do registro.

O **DICOM** é um padrão internacional de comunicação, armazenamento e representação de imagens médicas e dados derivados de tomografia computadorizada, ressonância magnética e radiografia, entre outros exames de imagem [DICOM, 2023]. Como os formatos de arquivo de imagem tradicionais (JPEG, TIFF, BMP) não são suficientes para o diagnóstico acurado, o padrão adiciona aos arquivos informações necessárias para fins de diagnóstico, como dados demográficos sobre o paciente, parâmetros de aquisição

para o estudo de imagem, dimensões da imagem, espaço de cores e uma série de informações adicionais para exibir corretamente a imagem no computador. Assim, permite-se a padronização das imagens médicas e dos dados associados, facilitando a interpretação e o diagnóstico pelos profissionais de saúde. A padronização do formato dos arquivos e do método de comunicação possibilita que as mídias sejam compartilhadas através de serviços como Sistema de Arquivo e Comunicação de Imagens (*Picture Archiving and Communication System – PACS*) e Sistema de Informação Radiológica (*Radiological Information System – RIS*), dando aos profissionais da saúde mais recursos para a análise clínica. O padrão foi desenvolvido desde 1983 pelo comitê formado pela Colégio Americano de Radiologia (*American College of Radiology – ACR*) e Associação Nacional de Fabricantes Elétricos (*National Electrical Manufacturers Association – NEMA*), e tem como foco facilitar a interoperabilidade entre equipamentos de imagens médicas. O comitê especifica os protocolos de rede para comunicação que os equipamentos devem utilizar para transportar os dados, a sintaxe e a semântica dos comandos associados à troca de dados no contexto de imagens médicas, um conjunto de definições para serviços de armazenamento das mídias, assim como a especificação de um formato de arquivo próprio e um padrão para a estrutura dos diretórios de armazenamento. Todas essas especificações e definições compõem o escopo do padrão DICOM que são expressadas em forma de classes Par Objeto-Serviço (*Service-Object Pair – SOP*). Essas classes representam serviços, como armazenamento usando rede, mídia ou *web*, operando em tipos de objetos de informação, como imagens tomografia computadorizada ou ressonância magnética. A Figura 4.4 apresenta o modelo geral dos serviços e funções DICOM e suas especificações para transporte dos dados de imagem, suas informações derivadas, comunicação em tempo real e para o acesso aos arquivos diretamente.

4.2.3. Padrões de Comunicação

O **FHIR** foi projetado com foco em implementação com flexibilidade, aproveitando as convenções de comunicação *web* já consolidadas, como representação de dados utilizando JSON, XML e troca de dados através de APIs RESTful baseadas em HTTP. O padrão dá suporte para troca de mensagens e documentos em sistemas desacoplados, ou com arquiteturas orientadas a serviços, indo ao encontro de tendências mais modernas para desenvolvimento de *software* em geral. Os Recursos definidos pelo FHIR são otimizados para a realização de transações sem manutenção de estado por meio de APIs RESTful. Transações desse tipo são as únicas que estão definidas até o momento pela especificação FHIR. As transações seguem um padrão simples de “solicitação” e “resposta”. As solicitações e respostas podem ocorrer para obtenção de carga útil individual ou em lote. A carga útil é composta por um cabeçalho e pelo conteúdo de interesse. A leitura de um Recurso, por exemplo, é feita através de uma operação `Read Request` que envia uma solicitação HTTP GET para o URL do Recurso⁶.

O **HL7 V2**⁷ é um padrão de troca de mensagens no contexto de aplicações médicas, tendo como função principal a definição de padrões para o conteúdo ou corpo das mensagens, protocolo de envio e recebimento de mensagens e definição de contextos va-

⁶Disponível em <https://www.hl7.org/fhir/overview-dev.html>

⁷Disponível em https://www.hl7.org/implement/standards/product_section.htm?section=13.

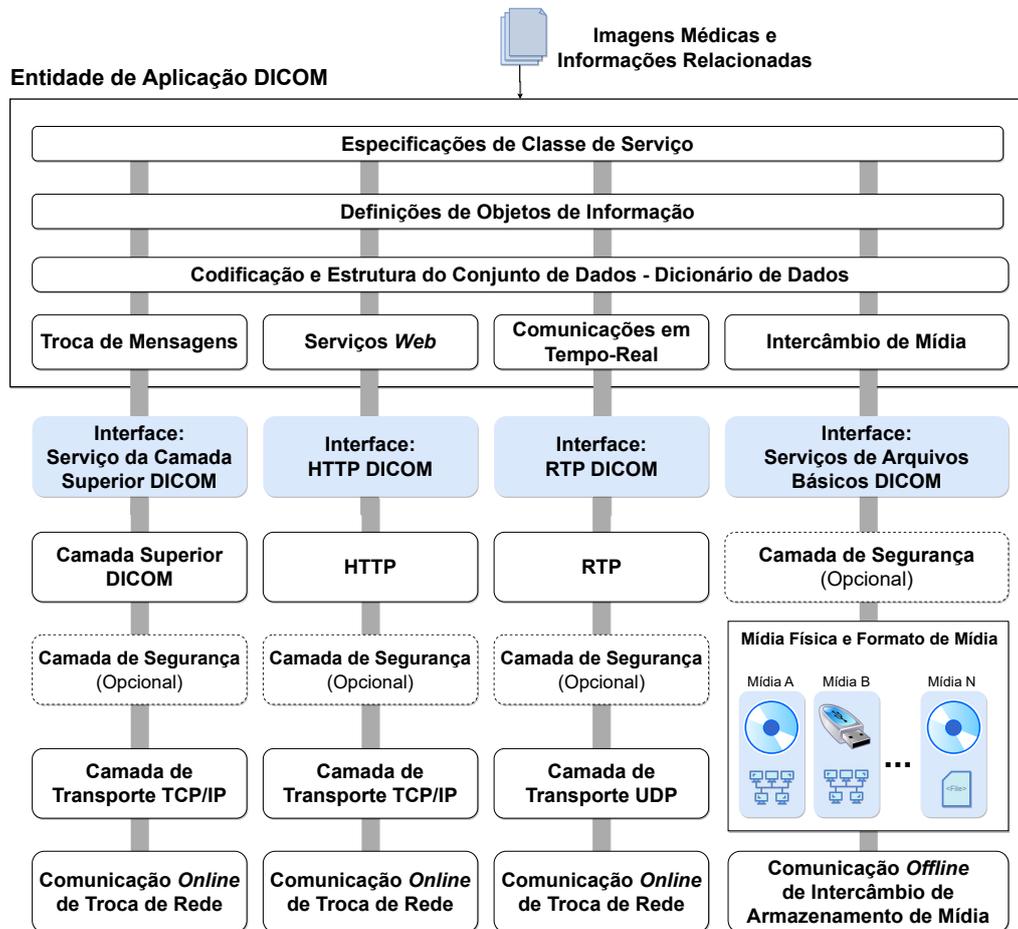


Figura 4.4. Modelo geral dos serviços de armazenamento, disponibilização e tratamento das imagens DICOM, juntamente com as funções para a transação de documentos DICOM, com saída para troca de mensagem, serviços *web* (REST API), transmissão em tempo real e exportação de arquivo para mídias físicas, que fazem parte da aplicação DICOM, geralmente disponibilizada em um servidor *online*. Na parte inferior da figura são apresentados os protocolos de comunicação e transporte especificados para cada tipo de serviço, servindo de base para a integração dos sistemas que consomem os dados da aplicação DICOM.

riados, tais como requisição de histórico, dados demográficos, entre outros. A estrutura de mensageria do HL7 V2 é baseada em um paradigma de mensageria baseada em eventos. O HL7 V2 define a sintaxe da comunicação em baixo nível, sem se preocupar que as mensagens sejam humanamente legíveis, introduzindo todo o conteúdo da mensagem em uma cadeia de caracteres. Os dados são separados por um sinal de barra vertical “|”, como mostra a Figura 4.5⁸. Do lado esquerdo existe um identificador do dado e do lado direito o valor. Os identificadores são definidos pelo padrão HL7 V2. Assim, a escolha de quais dados e valores devem estar na mensagem depende do contexto da requisição e do seu respectivo fluxo. A Figura 4.6 apresenta o fluxo de mensagens para transferir informações de imunização de um sistema de informações de saúde para outro. O Sistema Emissor

⁸Disponível em https://www.ringholm.com/docs/04300_en.htm

pode ser um sistema de EMR, um Sistema de Informações de Imunização (*Immunization Information System – IIS*) ou outro tipo de sistema de informações de saúde. Um evento como uma atualização ou novo registro inserido no Sistema Emissor inicia a criação e envio de uma mensagem VXU (*Vaccination Update*), contendo um registro de imunização atualizado. O Sistema Receptor recebe a mensagem e a processa de acordo com o perfil utilizado, aplicando regras de negócios locais. Após o processamento bem sucedido, o receptor envia uma mensagem de reconhecimento (*Acknowledgement – ACK*) e adiciona o novo registro ao Sistema Receptor [Savage, 2014].

```
MSH|^~&|GHH LAB|ELAB-3|GHH OE|BLDG4|200202150930||ORU^R01|CNTRL-3456|P|2.4<cr>
PID|||555-44-4444||EVERYWOMAN^EVE^E^^^L|JONES|19620320|F|||153 FERNWOOD DR.^
^STATESVILLE^OH^35292||((206)3345232|((206)752-121|||AC555444444||67-A4335^OH^20030520<cr>
OBR|1|845439^GHH OE|1045813^GHH LAB|15545^GLUCOSE|||200202150730|||
555-55-5555^PRIMARY^PATRICIA P^^^MD^^^|F|||||444-44-4444^HIPPOCRATES^HOWARD H^^^MD<cr>
OBX|1|SN|1554-5^GLUCOSE^POST 12H CFST:MCNC:PT:SER/PLAS:QN|^182|mg/dl|70_105|H||F<cr>
```

Figura 4.5. Exemplo de uma mensagem de resultado de exame de glicose e dados demográficos de um paciente no padrão HL7 V2. Do lado esquerdo do “|” existe um identificador do dado e do lado direito o valor desse dado.

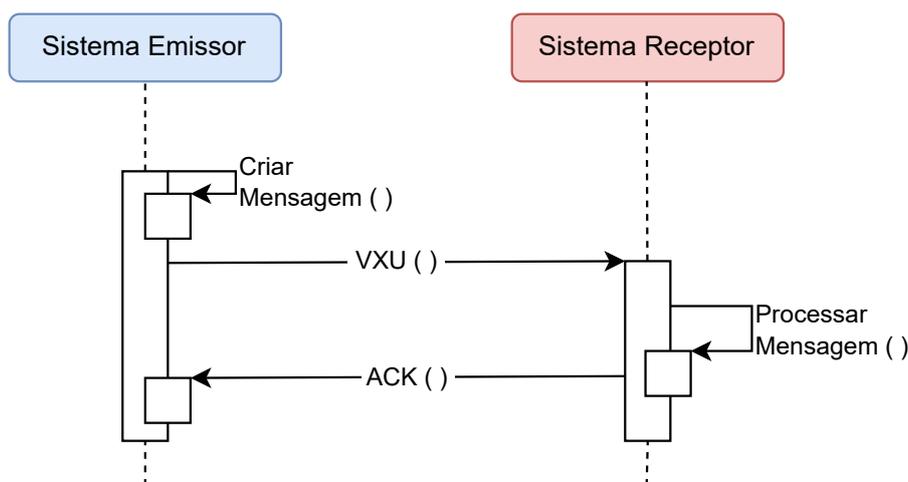


Figura 4.6. Diagrama de sequência da especificação do fluxo de atualização do histórico de imunização de um paciente utilizando o padrão HL7 V2. Adaptado [Savage, 2014].

O HL7 V3⁹ difere do HL7 V2 ao incorporar um Modelo de Informação de Referência (*Reference Information Model – RIM*) para configurar o formato de mensagens em uma modelagem orientada a objetos. No HL7 V3, as mensagens são codificadas em um mapeamento de classes de informações necessárias para o contexto de aplicações médicas. Cada classe recebe seu Identificador Único de Objeto (*Object Identifier – OID*) para assegurar a universalidade da especificação de cada objeto no seu contexto. As especificações apresentam atributos já conhecidos no HL7 V2, como dados demográficos, relacionamentos e os fluxos de troca de dados como máquinas de estado. Contudo, com a utilização do RIM, o HL7 V3 também ganha especificações para subconjuntos das classes

⁹Disponível em https://www.hl7.org/implement/standards/product_brief.cfm?product_id=186.

do RIM, ou seja, no HL7 V3 as classes são organizadas e reutilizadas para diferentes contextos médicos, sendo isso também parte da especificação do padrão. Consequentemente, o padrão HL7 V3 foi organizado de forma orientada a contexto de uso, ou de especificação de domínio, que são conjuntos de classes do RIM que formam um grupo aplicado a alguma área do domínio dos sistemas médicos, como atendimento, exames, cobrança, atendimento emergencial, conhecidos como Modelo de Informação de Mensagem de Domínio (*Domain Message Information Model – D-MIM*).

Todos os fluxos, protocolos de comunicação e terminologias adotadas para o HL7 V2 dão base para o HL7 V3, que traz como foco especificar a codificação das mensagens utilizando XML e sua sintaxe. Dessa forma, o padrão torna-se mais inteligível e de fácil implementação. A Figura 4.7¹⁰ apresenta um trecho da mesma mensagem apresentada na Figura 4.5, porém estruturada de acordo com o padrão HL7 V3. O exemplo mostra o resultado do teste de glicose de um paciente, junto com informações adicionais que acrescentam semântica aos dados de forma hierárquica.

```
<observationEvent>
  <id root="2.16.840.1.113883.19.1122.4" extension="1045813"
    assigningAuthorityName="GHH LAB Filler Orders"/>
  <code code="1554-5" codeSystemName="LN"
    codeSystem="2.16.840.1.113883.6.1"
    displayName="GLUCOSE^POST 12H
CFST:MCNC:PT:SER/PLAS:QN"/>
  <statusCode code="completed"/>
  <effectiveTime value="200202150730"/>
  <priorityCode code="R"/>
  <confidentialityCode code="N"
    codeSystem="2.16.840.1.113883.5.25"/>
  <value xsi:type="PQ" value="182" unit="mg/dL"/>
  <interpretationCode code="H"/>
  <referenceRange>
    <interpretationRange>
      <value xsi:type="IVL_PQ">
        <low value="70" unit="mg/dL"/>
        <high value="105" unit="mg/dL"/>
      </value>
      <interpretationCode code="N"/>
    </interpretationRange>
  </referenceRange>
</observationEvent>
```

Figura 4.7. Exemplo de mensagem do resultado de um exame de glicose de um paciente no padrão HL7 V3. Em relação a conteúdo, os padrões HL7 V2 e V3 são igualmente abrangentes. Entretanto, no HL7 V3 a representação dos dados em XML facilita o entendimento do contexto. Contudo, aumenta-se o tamanho da mensagem em relação à versão anterior.

Além da padronização da representação de imagens, o DICOM especifica um protocolo para troca de mensagens. O protocolo fornece um arcabouço de comunicação para os serviços DICOM e é compatível com os protocolos TCP e IP. Essa compatibilidade possibilita a comunicação pela Internet entre aplicações distintas, que implementem o padrão DICOM. O protocolo de comunicação DICOM foi desenvolvido com base no mo-

¹⁰Disponível em https://www.ringholm.com/docs/04300_en.htm

delo de referência de Interconexão de Sistemas Abertos (*Open Systems Interconnection* – OSI) e implementa funcionalidades das camadas de aplicação, apresentação e sessão^[11]. Uma aplicação que utiliza o protocolo DICOM é denominada Entidade de Aplicação (*Application Entity* – AE). Cada AE pode solicitar ou fornecer um dos serviços do protocolo DICOM e esses serviços são denominados classes de serviços. Cada classe de serviço consiste de dados e uma função relacionada àquele dado. Por exemplo, uma imagem de ressonância magnética pode ser associada a diferentes funções como imprimir ou armazenar. Quando uma AE solicita um serviço, desempenha o papel de Usuário de Classe de Serviço (*Service Class User* – SCU) e quando a AE fornece o serviço desempenha o papel de Provedor de Classe de Serviço (*Service Class Provider* – SCP). A comunicação entre duas AEs requer o estabelecimento de uma sessão, denominada “associação”. O estabelecimento da associação inicia com a troca de informações importantes como a codificação de dados suportada e os serviços fornecidos pelo SCP. Após a associação, o SCU pode solicitar as classes de serviço ao SCP. Após o envio das classes de serviço, a associação é finalizada [Maani et al., 2011]. É importante destacar que, apesar de especificar um padrão de comunicação, o protocolo de comunicação DICOM não é genérico, sendo capaz de realizar apenas a troca de mensagens DICOM.

4.2.4. Padrões de terminologia

Os padrões de terminologias evitam a ambiguidade e aumentam a clareza do conteúdo ao armazenar informações em sistemas distintos, sendo essenciais para a interoperabilidade entre sistemas de registros médicos. Esses padrões definem um conjunto de códigos e sistemas de classificação que representam conceitos de saúde de forma a estabelecer uma forma de representação unificada [Massad et al., 2003].

No Brasil, a ANS em parceria com a AMB e o COPISS^[12] desenvolveram a TUSS, que é um padrão de codificação de procedimentos médicos utilizados em planos de saúde privados. A tabela TUSS, como ficou conhecida, define a nomenclatura dos procedimentos médicos e seus respectivos códigos identificadores, grupos e subgrupos. Para facilitar a integração do padrão aos sistemas dos prestadores de serviços de saúde, a ANS disponibilizou o padrão TUSS como uma planilha em formato *xlsx*^[13]. Ao conceder a terminologia nesse formato, a TUSS possibilita que os usuários da planilha possam buscar códigos de procedimentos de forma ágil, utilizando o nome padronizado dos procedimentos e as ferramentas disponíveis em *software* de planilhas eletrônicas. Além disso, o formato em tabela agiliza a carga de novas atualizações do padrão para uma base de dados, permitindo que os sistemas integrados se mantenham atualizados.

O SNOMED CT^[14] é um padrão de terminologia clínica multilínguas utilizado para representar conceitos médicos em sistemas de saúde, tendo como foco a integração de terminologias de vários países. O padrão tem uma grande abrangência, com mais de

¹¹Disponível em https://docs.oracle.com/cd/E57425_01/121/IMDCM/ch_intro.htm#IMDCM13799

¹²Nota da ANS http://www.ans.gov.br/images/stories/Plano_de_saude_e_Operadoras/Area_do_consumidor/nota13_geas_ggras_dipro_17012013.pdf.

¹³Disponível em https://www.gov.br/ans/pt-br/arquivos/assuntos/consumidor/o-que-seu-plano-deve-cobrir/correlacaotuss-rol_2021_site.xlsx

¹⁴Disponível em <https://www.snomed.org/five-step-briefing>.

350 mil conceitos médicos especificados em sua terminologia. Para organizar essa vasta coleção de conceitos, o padrão organiza os termos em três componentes:

- **Conceitos:** identificador único e computável, utilizado para garantir a unicidade de cada termo;
- **Descrições:** descrição de uma ideia clínica capturada de forma única e completa chamada de Nome Completamente Especificado (*Fully-Specified Name* – FSN), juntamente com um conjunto de sinônimos que guardam a informação do nome do termo nos múltiplos idiomas suportados pelo padrão;
- **Relacionamentos:** Registram as relações entre os conceitos, podendo ser de diversos tipos especificados pelo padrão. Relacionamentos podem representar hierarquia entre os conceitos, de forma que o conceito tem sempre no mínimo um relacionamento do tipo “é um”, que define seu tipo.

Além de especificar a terminologia, o SNOMED CT especifica formas de implementação para o armazenamento dos dados de terminologia nos sistemas, servindo também como base para o auxílio no desenvolvimento de aplicações médicas. Um detalhe importante sobre o padrão é que, apesar de ser uma fundação sem fins lucrativos, a SNOMED cobra uma taxa para associação na organização e acesso à terminologia, caso o usuário venha de uma região sem órgãos federados à fundação¹⁵.

Com o intuito de evitar ambiguidade nos campos de observação dos registros clínicos o **LOINC** propõe uma terminologia para os possíveis tipos de observação em resultados de exames e testes laboratoriais. Surgindo nesse contexto, o LOINC desenvolveu uma base de dados amplamente utilizada para categorização e identificação de observações de exames laboratoriais e dados clínicos, tais como observações clínicas, questionários e outras avaliações de saúde. O padrão define um conjunto de códigos numéricos e nomes padronizados para identificar as observações, aprimorando a comunicação e compartilhamento de dados entre sistemas de saúde. Em contraste com outras terminologias, o LOINC tem como objetivo principal criar diferentes códigos para cada tipo de teste, exame e observações, para serem usados nos campos de observação dos padrões de comunicação, como no HL7 v2. Paralelamente, o LOINC adiciona semântica às tradicionais terminologias difundidas, podendo combiná-las para expandir a capacidade de especificação e passagem de informação na troca de mensagem de registros médicos.

Para atingir seu objetivo, o LOINC categoriza os códigos por meio de uma lógica de seis dimensões de especificação, sendo elas: (i) Componente (ou Analito), representando a substância ou entidade que está sendo medida ou observada; (ii) Propriedade, representando a característica ou atributo do analito; (iii) Tempo, representando o intervalo de tempo sobre o qual uma observação foi feita; (iv) Sistema, representando o espécime ou substância sobre a qual a observação foi feita; (v) Escala, definindo como o valor da observação é quantificado ou expresso; (vi) Método (opcional), representando uma classificação de alto nível de como a observação foi feita, geralmente utilizado quando a técnica afeta a interpretação clínica dos resultados.

¹⁵Disponível em <https://www.snomed.org/get-snomed>.

A união das seis dimensões da formalização do nome é chamada de FSN, que passa a ser, junto com o identificador numérico, a definição do tipo de observação. Além do FSN, o LOINC também especifica versões mais longas e humanamente legíveis do nome completo, o *Long Common Name* (LCN), juntamente com uma versão curta, o *Short Name*, para ser usada em colunas de tabelas ou relatórios. Apesar da especificação e definição de FSNs para as observação, apenas o código da especificação é enviado pelas mensagens. Para chegar na definição do código é necessário consultar a base do LOINC, utilizando o código numérico, através da API FHIR do LOINC¹⁶, pela página *web* oficial ou tendo a base completa integrada ao sistema. A Tabela 4.2 apresenta um exemplo¹⁷ dos passos para a especificação de uma observação para contagem manual de glóbulos brancos em amostra de líquido cefalorraquidiano. Esse processo mostra os passos que o LOINC segue para a categorização de forma única os diferentes tipos de observações clínicas, gerando, no fim, um identificador textual que resume completamente o contexto do valor da observação. O FSN, marcado em cinza claro e negrito, é formado pela junção das seis partes especificadas pelo padrão. As versões longas e curtas do nome também são apresentadas na tabela nas linhas em cinza claro.

Tabela 4.2. Exemplo da aplicação das seis partes do padrão LOINC para um exame de contagem manual de glóbulos brancos em amostra de líquido cefalorraquidiano, código LOINC 806-0. FSN marcado em cinza claro e negrito, formado pela junção das seis partes especificadas pelo padrão. Versões longas e curtas nas linhas em cinza claro.

Passo	Valor
Analito	Leukocytes
Propriedade	NCnc (<i>Number concentration</i>)
Tempo	Pt (<i>Point in time</i>)
Sistema	CSF (<i>Cerebral spinal fluid</i>)
Escala	Qn (<i>Quantitative</i>)
Método	<i>Manual Count</i>
FSN	Leukocytes: NCnc: Pt: CSF: Qn: Manual count
LCN	Leukocytes [# /volume] in Cerebral spinal fluid by Manual count
Short Name	WBC # CSF Manual

Com o intuito de aprimorar o levantamento estatístico das causas de morte e morbidade ao redor do mundo, a Organização Mundial da Saúde (OMS) desenvolveu o ICD, que atualmente está na 11ª edição, sendo referenciado como ICD-11. A classificação de doenças para registro com a finalidade de estudos estatísticos tem um papel fundamental na tomada de decisões em larga escala, com implicação no planejamento de ações governamentais e alocação de recursos de forma inteligente. Consequentemente, o impacto do planejamento baseado em dados leva a uma melhoria na qualidade dos serviços de saúde prestados à população [Harrison et al., 2021]. O ICD-11 é uma base de dados organizada de forma estatística e hierárquica que contém categorias para doenças e distúrbios, condições relacionadas à saúde, causas externas de doença ou morte, anatomia, ambientes, atividades, medicamentos, vacinas e outras informações que possam influenciar a saúde. Todos esses níveis de classificação são especificados na base de acordo com as

¹⁶Disponível em <https://loinc.org/fhir/>

¹⁷Exemplo retirado da página *web* oficial do LOINC, disponível em <https://loinc.org/get-started/loinc-term-basics/>.

suas respectivas categorias, recebendo códigos de identificação alfanuméricos únicos e sequenciais, definindo uma hierarquia de doenças relacionadas [WHO, 2022].

Para consultas na base de dados do ICD-11 a OMS disponibiliza uma API REST sobre HTTP, interface gráfica *web*¹⁸ e uma ferramenta de codificação, em que os usuários podem montar o código ICD-11 correto para uma doença e suas informações adicionais. A ferramenta é útil para teste e validação de *software* que utilize o sistema de códigos ICD-11. A Figura 4.8 apresenta a interface *web* da ferramenta de codificação do ICD, com destaque para um código ICD-11 gerado apenas selecionando as características de uma doença.

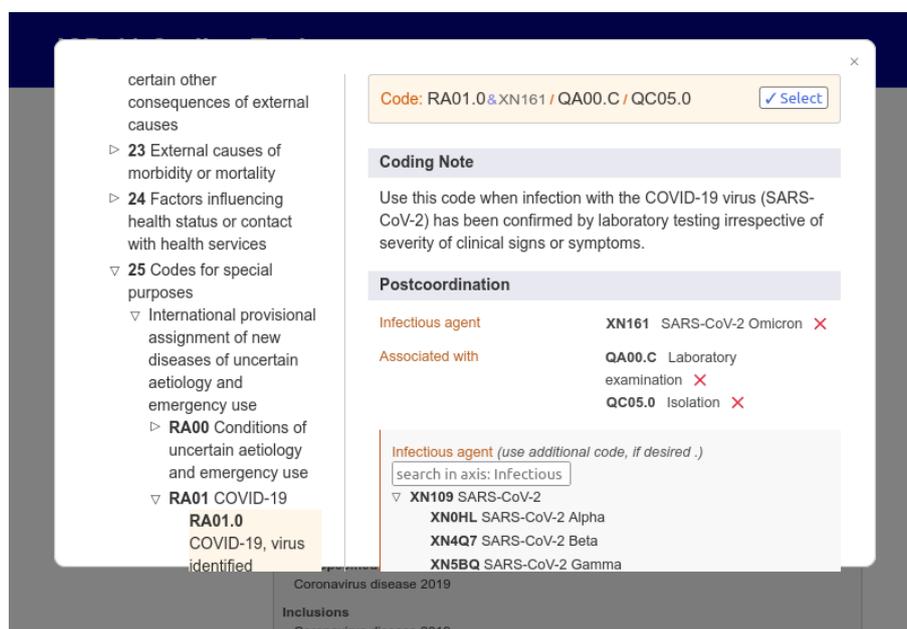


Figura 4.8. Aplicação *web* do ICD-11 disponibilizado pela OMS apresentando a ferramenta de codificação. O usuário pode buscar palavras-chave e selecionar a combinação de fatores desejada para um registro. O exemplo mostra o código gerado para a doença COVID-19 confirmada por teste laboratorial, com o vírus na sua variante SARS-CoV-2 Omicron, tendo o paciente em isolamento.

4.3. Fundamentos da Tecnologia de Cadeia de Blocos

A cadeia de blocos (*blockchain*) compreende uma tecnologia composta essencialmente por dois elementos básicos, uma estrutura de dados de encadeamento dos blocos e uma rede par-a-par (*Peer-to-Peer* – P2P) capaz de armazenar transações de forma ordenada e distribuída. Como principal diferencial, a tecnologia de cadeia de blocos viabiliza o desenvolvimento de aplicações distribuídas seguras em cenários marcados pela desconfiança mútua entre entidades, enquanto dispensa a necessidade de uma terceira entidade centralizadora, atuando como âncora de confiança para assegurar a segurança entre transações na rede [Mattos et al., 2018]. Diante dessas características, a cadeia de blocos é comumente interpretada como um livro-razão (*ledger*) distribuído por diversos terminais de uma rede.

¹⁸Disponível em <https://icd.who.int/browse11/l-m/en>.

Embora não haja unanimidade na literatura, as redes de cadeias de blocos podem assumir diferentes classificações: privada, pública, permissionada e não permissionada. Redes públicas e privadas contrapõem-se em relação ao controle de acesso à rede e ao conteúdo da cadeia. Redes públicas, de conteúdo aberto, são caracterizadas pela ausência de um mecanismo de controle de acesso. Além disso, a intermitência de nós em uma rede pública não causa quaisquer prejuízos ao mecanismo de consenso ou à geração de novos blocos. Diferentemente, as redes privadas detêm um conteúdo fechado e adotam medidas de controle de acesso restritas que impedem que nós sem autorização acessem a rede par-a-par e o conteúdo armazenado nos blocos da cadeia. As redes permissionadas e não permissionadas se diferenciam pelas atividades desempenhadas pelos nós na rede. Na rede não permissionada, há uma isonomia de papéis na rede, a qual garante que todos os nós possam desempenhar as mesmas funções, isto é, gerar transações, competir na mineração de blocos e participar do mecanismo de consenso. Em contraste, os nós pertencentes a redes permissionadas podem assumir papéis distintos de acordo com a necessidade da aplicação. Ao associar as características de cada par de classificações, cria-se a taxonomia de redes pública não permissionada, pública permissionada, privada não permissionada e privada permissionada [Mattos et al., 2018].

A tecnologia de cadeia de blocos oferece resistência à adulteração, uma vez que a alteração dos dados de um bloco de transações requer a manipulação de todos os blocos posteriores. Além disso, o caráter descentralizado das cadeias de blocos impede a existência de um ponto único de falha, centralizado, que prejudicaria a segurança e a privacidade das transações realizadas dado que eventuais conflitos de interesses entre as partes envolvidas podem ocorrer. Dessa forma, os nós participantes da rede par-a-par acessam uma réplica idêntica da cadeia de blocos armazenada localmente. Para evitar inconsistências e garantir a distribuição de réplicas coerentes dos dados, é necessário adotar mecanismos de validação e de consenso. Como os blocos da cadeia são compostos por uma sequência de transações a serem executadas, os nós precisam antecipadamente alcançar um consenso e concordar com as transações inseridas no bloco bem como com a ordem em que serão executadas. O processo de validação de transações, também denominado mineração, em certos casos, é desempenhado por um mecanismo de consenso. Esse mecanismo estabelece regras para validação e difusão de transações e blocos, resolvendo potenciais conflitos, e alcançando uma consistência eventual da informação presente na rede [Xu et al., 2017]. Ao se alcançar o consenso, garante-se a integridade, a consistência e a imutabilidade da cadeia de blocos. É válido destacar que cada bloco adicionado à cadeia tem como parte de seu conteúdo o resumo criptográfico do bloco anterior. Assim, os mecanismos de consenso e a forma como os blocos são encadeados tornam improvável a modificação do conteúdo de um bloco por um nó individual. Logo, há garantia de preservação do histórico de transações armazenadas nos blocos, impossibilitando a remoção ou edição de dados e a alteração da ordem das ações registradas. O registro de uma transação na cadeia de blocos requer que cada nó participante da rede aplique criptografia assimétrica, garantindo a veracidade e o não-repúdio dos dados armazenados. Também há garantia de pseudo-anonimato das partes envolvidas nas transações, uma vez que as identidades das partes são ocultadas da rede [Pustokhin et al., 2021].

Dentre os principais mecanismos de consenso para cadeias de blocos empregadas no setor de saúde estão:

- **Prova de Trabalho** (*Proof-of-Work* – PoW) é um mecanismo de consenso probabilístico que implementa uma lógica baseada na competição entre mineradores. Os mineradores são nós que buscam resolver um desafio criptográfico difícil para que as transações escolhidas sejam registradas em um bloco inserido na cadeia de blocos. A resolução do desafio é feita por força bruta e a solução é encontrada quando o nó descobre um valor numérico, chamado *nonce* criptográfico. Juntamente com as transações selecionadas, o *nonce* é adicionado ao bloco candidato a ser incorporado à cadeia de blocos. Em seguida, o bloco candidato é disseminado por toda a rede para que seja validado pelos demais nós. Para incentivar esse processo de resolução por força bruta, uma recompensa é oferecida ao minerador, ou grupo de mineradores, que primeiro resolver o desafio [Nakamoto, 2008]. Na PoW, a probabilidade de um nó conseguir minerar um bloco está atrelada ao poder computacional do nó.
- **Prova de Participação** (*Proof-of-Stake* – PoS) também é um mecanismo de consenso probabilístico, porém a probabilidade de sucesso na mineração de um bloco depende da participação dos nós na rede. Os nós mineradores competem para encontrar um valor de resumo criptográfico menor ou igual a um valor alvo para que possam minerar um bloco. Todavia, a dificuldade de determinar o resumo criptográfico é inversamente proporcional à riqueza acumulada (*coin age*) daquele nó. A riqueza acumulada é definida como a quantidade de recursos do nó multiplicada pelo período em que o nó reteve aquele recurso. Logo, o nó detentor da maior participação e riqueza acumulada, possivelmente terá a maior a probabilidade de validar o próximo bloco [Tschorsch e Scheuermann, 2016].
- **Prova de Autoridade** (*Proof-of-Authority* – PoA) é um mecanismo de consenso amplamente adotado em redes privadas caracterizado pela presença de uma entidade responsável por designar um conjunto de nós com autoridade. Os nós com autoridade são encarregados da tarefa de gerar novos blocos e validar as transações. Assim, a inclusão de qualquer bloco candidato na cadeia é precedida pela sua validação e assinatura por pelo menos um nó com autoridade. A manutenção da natureza distribuída da rede é garantida pela necessidade de uma concordância unânime entre os nós de autoridade sobre o estado global da cadeia. Para evitar disputas e desperdícios de recursos, algumas plataformas aplicam um esquema rotativo de geração de blocos, fato que garante um intervalo de tempo exclusivo a cada nó de autoridade. Eventuais falhas em nós de autoridade precisam ser detectadas pela plataforma e acarretam a remoção da autoridade do nó falho e a consequente desconsideração dos blocos minerados por ele [Cachin e Vukolic, 2017].
- **Raft** é o principal mecanismo de consenso usado no Hyperledger Fabric¹⁹, recomendado para ambientes de produção [Carrara et al., 2020]. É um mecanismo tolerante a falhas de parada e é baseado no modelo líder-seguidor. O Raft alcança o consenso por meio da eleição de um líder, replicação de *log* e estágios de segurança. Os nós podem estar em três estados: candidato, seguidor ou líder. Inicialmente, os nós são seguidores e, se nenhum líder for detectado, ocorre uma eleição. O líder se comunica com os clientes, mantém o estado de seguidor e replica entradas de *log*.

¹⁹Disponível em <https://www.hyperledger.org/use/fabric>.

O líder usa uma chamada de procedimento remota *AppendEntries* para replicar *logs* e validar o estado do seguidor. O Raft garante que as transações sejam inseridas na mesma ordem nos nós e garante que o líder eleito tenha os *logs* mais recentes. O Raft oferece vantagens como fácil implementação em linguagens de programação mais comuns e um sistema de eleição eficiente. No entanto, requer capacidade de armazenamento significativa e tem limitações como a ausência de tratamento de falhas Bizantinas²⁰.

- **Tolerância Prática a Falhas Bizantinas** (*Practical Byzantine Fault Tolerance – PBFT*) é um mecanismo de consenso determinístico amplamente utilizado em sistemas distribuídos e plataformas de cadeia de blocos como Zilliqa e Hyperledger Fabric. O mecanismo lida com falhas no envio de mensagens e atrasos nas redes, assumindo falhas independentes e dependência parcial entre os nós. O PBFT garante segurança e vivacidade, mesmo com até $(n - 1)/3$ nós maliciosos entre um total de n nós. O algoritmo envolve quatro etapas: (i) o cliente envia uma solicitação de transação ao líder; (ii) o líder a encaminha para outros nós; (iii) esses nós executam a requisição e (iv) enviam uma resposta ao cliente que espera $2f + 1$ respostas consistentes, em que f é o número máximo tolerado de respostas falhas. O PBFT lida com líderes defeituosos por meio de troca de liderança baseada em alternância (*round-robin*). O mecanismo tem como vantagens o baixo consumo de energia e rápido tempo de execução em relação a outros mecanismos resistentes a falhas Bizantinas, mas apresenta limitações em redes maiores devido ao aumento da troca de mensagens e vulnerabilidade a ataques de personificação (*Sybil*). O PBFT é um mecanismo de consenso prático que garante comunicação e acordo confiáveis entre os nós, ao mesmo tempo em que mitiga o impacto de nós mal-intencionados [Carrara et al., 2020].

Introduzido primeiramente na plataforma de computação confiável Ethereum, o contrato inteligente (*smart contract*) consiste em uma aplicação autoexecutável armazenada na cadeia de blocos, que traduz as cláusulas de um contrato real para código. Através de um endereço conhecido e acessível, o contrato inteligente possui um conteúdo que pode ser inspecionado por todos os participantes da rede. Internamente, um contrato inteligente contém regras contratuais acordadas entre as partes, que tornam a violação proibitiva computacionalmente e, portanto, não vantajosa a potenciais violadores. Em contraste a contratos não determinísticos, que inviabilizam o consenso devido à aleatoriedade dos resultados atingidos por diferentes nós da rede, os contratos inteligentes são naturalmente determinísticos [Christidis e Devetsikiotis, 2016, Mattos et al., 2018], o que garante a convergência da visão global da rede. Como todas as interações com um contrato ocorrem via mensagens assinadas, é possível rastrear todos os participantes envolvidos na operação do contrato. O acionamento do contrato pode ser desencadeado por qualquer mudança de estado ou registro de transação na cadeia de blocos, facilitando a negociação, validação e execução comercial sem a necessidade de terceiros [Pustokhin et al., 2021]. Devido à imutabilidade da cadeia de blocos, quaisquer erros cometidos no código de um contrato inteligente já implementado não são passíveis de correção. Além disso, mudan-

²⁰Falha Bizantina refere-se ao comportamento de um nó que foge ao comportamento esperado do protocolo definido.

ças nas circunstâncias relacionadas à execução do contrato, como modificações em leis e regulamentações, são igualmente complexas de serem contabilizadas pelo contrato já implementado. Isso impõe a necessidade de revisões extensas e potencialmente custosas do código do contrato inteligente por especialistas.

4.4. Desafios de Segurança e Privacidade no Acesso a Dados de Saúde

No Brasil, o aplicativo ConecteSUS²¹ é responsável por disponibilizar informações de saúde do país. Na plataforma é possível que os cidadãos consigam, por meio de um dispositivo móvel ou acesso *web*, visualizar seu histórico clínico, incluindo carteira de vacinação, resultados de exames laboratoriais, medicamentos utilizados entre outras informações. Segundo o Banco Mundial, em 2022, o Brasil foi reconhecido como o segundo país do mundo com maior maturidade em governo digital²². Atualmente 80% da população brasileira, correspondendo a aproximadamente 140 milhões de usuários, já possui acesso a essas plataformas. Nos Estados Unidos, entre os anos de 2009 e 2019, houve mais de 3.000 violações de dados de saúde, cada uma envolvendo pelo menos 500 registros de pacientes. Em 2019, 572 violações envolvendo mais de 41 milhões de americanos foram relatadas [Luh e Yen, 2020]. Com o aprimoramento de modelos de inteligência artificial, os dados de pacientes podem ser utilizados para treinamento em servidores centralizados e com poucas camadas de segurança, facilitando a manipulação indevida dessas informações por atacantes [Rahman et al., 2021]. Esse treinamento sem as devidas regras de segurança, pode afetar hospitais que compartilham dados com entidades de pesquisa [Salim e Park, 2023], uma vez que são diretamente os responsáveis pela guarda desses dados.

Todos os ataques já conhecidos e amplamente explorados em sistemas computacionais, como Negação de Serviço Distribuído (*Distributed Denial of Service* – DDoS), *phishing*, *ransomware* e engenharia social, se aplicam também no contexto de registros médicos eletrônicos. A principal motivação dos atacantes está na comercialização de dados pessoais e, em alguns casos, espionagem relacionada ao roubo de patentes e propriedade industrial. Na maioria dos ataques bem sucedidos, a negligência e ingenuidade por parte dos usuários pode ser um fator decisivo para comprometer toda a infraestrutura e os sistemas, independente da finalidade. Ao utilizar senhas fracas, compartilhar credenciais e acessar sites e endereços *web* sem a devida atenção, o vazamento de dados pessoais pode acontecer de maneira quase que instantânea. Diante disso, criar mecanismos que garantam a transparência, confidencialidade e integridade dos registros médicos eletrônicos, torna-se indispensável no cenário atual. Tecnologias como cadeia de blocos e contratos inteligentes, podem e devem guiar os próximos anos de segurança computacional na área de saúde.

Uma das preocupações indispensáveis ao manipular EMRs é que esses dados são privados e pertencem aos pacientes, porém são totalmente controlados por instituições de saúde [Lesk, 2013]. Outra preocupação está relacionada ao Gerenciamento de Identidade (*Identity Management* – IM), pois aumenta a confiança e a privacidade dos sistemas de

²¹Disponível em <https://conectesus.saude.gov.br/home>.

²²Disponível em <https://www.gov.br/pt-br/noticias/financas-impostos-e-gestao-publica/2022/11/brasil-e-reconhecido-como-segundo-lider-em-governo-digital-no-mundo>.

EMR [Tormo et al., 2013]. O IM para sistemas de armazenamento e consulta de registros médicos eletrônicos tende a ser centralizado, o que introduz um ponto único de falha e um gargalo de acesso para todo o sistema [Dubovitskaya et al., 2017]. Portanto, embora existam diferentes propostas baseadas em cadeia de blocos para armazenar e compartilhar os registros eletrônicos [Dubovitskaya et al., 2017, Zhang e Poslad, 2018, Yue et al., 2016], há oportunidade de melhoria para a oferta de um serviço mais seguro e adaptado às dores do mercado. Os sistemas EMR são comumente implementados com práticas precárias de segurança, podendo comprometer a privacidade e a confidencialidade dos dados do paciente [Jacquemard et al., 2020]. Além disso, o compartilhamento dos dados com finalidades comerciais pode ainda prejudicar a confiança nos planos e operadores de saúde. Os sistemas EMR possuem informações consideradas altamente confidenciais por vários motivos, havendo assim, uma forte necessidade de confidencialidade. A integridade dos registros médicos torna-se essencial, pois um tratamento incorreto baseado em dados errôneos pode ser fatal. Além disso, a disponibilidade é tão essencial quanto a integridade, pois as informações do sistema devem estar disponíveis para o tratamento adequado a qualquer instante [Haas et al., 2011]. O principal objetivo de um sistema EMR é a disponibilidade de dados do paciente. Nesse sentido, o controle de acesso não deve impedir qualquer solicitação legítima em nome do interesse vital dos pacientes [de Oliveira et al., 2023].

4.4.1. Controle de acesso a dados médicos

Um dos principais métodos para controle de acesso baseia-se na abordagem de permissionamento conhecida como Controle de Acesso baseado em Papéis (*Role-based Access Control* – RBAC). Nessa abordagem, cada usuário pode possuir um ou mais papéis, ou funções, tais como administradores, médicos, pacientes entre outros, definindo perfis distintos de permissão de acesso. Geralmente, um administrador fornece papéis específicos para cada usuário e cada função possui certos níveis de permissão. A Figura 4.9 apresenta o modelo de controle de acesso RBAC. Sistemas baseados nesse modelo podem comprometer a segurança pela complexidade no gerenciamento de grupos e usuários, em que permissões podem ser concedidas sem a real necessidade. No caso de registros médicos eletrônicos, o acesso aos dados do paciente tem como desafio determinar qual situação o paciente está em um dado momento. Uma consulta tradicional ou atendimento de emergência são exemplos dessas situações. No caso de emergência, o acesso aos dados deve ser permitido em caráter excepcional. O RBAC, por exemplo, não possui flexibilidade para acesso aos dados em casos imprevisíveis como em uma emergência. Nesse sentido, caso um paciente precise de atendimento e o médico disponível não tenha os papéis necessários naquele momento para acesso aos dados, o atendimento pode ser comprometido. Nesse sentido, alguns trabalhos propõem uma variação denominada Controle de Acesso baseado em Papéis de Emergência (*Emergency Role-Based Access Control* – E-RBAC), na qual são definidas as funções de emergência com base no nível de acesso que o usuário solicitante possui e posteriormente permite a consulta aos dados caso o paciente esteja na situação de emergência [Nazerian et al., 2019]. Embora diversas abordagens utilizem o RBAC como controle de acesso, esse modelo possui desafios quanto à escalabilidade, em função da possibilidade no aumento de papéis e políticas de forma indiscriminada [Seo et al., 2018].

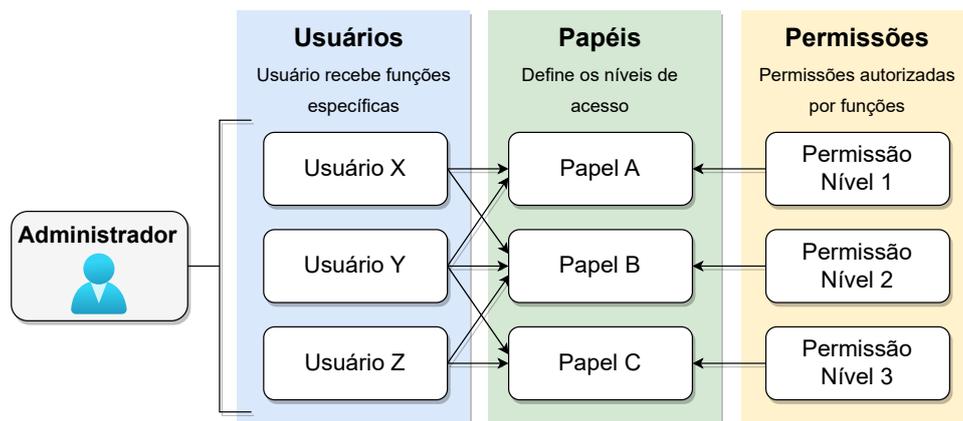


Figura 4.9. Modelo de controle de acesso baseado em papéis (RBAC). O administrador do sistema define quais os papéis e permissões existentes no sistema. Uma vez definidos, atribui para cada usuário um papel e o usuário pode exercer mais de um papel. Cada papel possui respectivos níveis de permissão.

Outra abordagem para controle de acesso é denominada SitBAC (*Situation-based access control*) [Peleg et al., 2008]. Essa abordagem considera a situação atual do paciente em vez do papel. A permissão de acesso aos dados é concedida mediante solicitações, diferentemente do RBAC que separa os usuários e suas permissões em relação a um conjunto de recursos. O SitBAC considera que a decisão da descoberta de dados dos pacientes é afetada por fatores que compõem a situação de acesso aos dados desses pacientes, como o solicitante dos dados, a tarefa a ser executada, uma autorização legal, entre outros. Cabe destacar que não fica evidenciado como o SitBAC pode ser utilizado juntamente com o RBAC, uma vez que ele é uma generalização ou superconjunto do RBAC. Além disso, o SitBAC não aborda questões básicas de segurança como confidencialidade, integridade e não-repúdio [Seol et al., 2018].

O modelo de Controle de Acesso baseado em Trabalho (*Work-based access control* – WBAC) foca o trabalho a ser executado pelo profissional e pela equipe. Nesse modelo, as atribuições de um dado usuário são modificadas de acordo com o tratamento que será desempenhado. Por exemplo, um cenário de separação de tarefas é utilizado para evitar fraudes através da identificação de papéis conflitantes [Abomhara e Ben Lazrag, 2016]. Nesse exemplo, um usuário em uma equipe só pode ser atribuído a um papel de equipe em um determinado momento. Nesse sentido, o modelo WBAC é definido pelos usuários atribuídos a papéis ou equipes, os membros da equipe que podem ser atribuídos a papéis de equipe e o trabalho, que pode ser atribuído a equipes. Por fim, as permissões podem ser associadas a papéis individuais e papéis de equipe [Abomhara et al., 2016]. Um dos principais desafios do WBAC é o gerenciamento das tarefas para cada usuário, o que pode aumentar a complexidade e erros durante atribuição dessas tarefas.

O modelo de Controle de Acesso baseado em Atributo (*Attribute-Based Access Control* – ABAC) define um paradigma de controle de acesso pelo qual os direitos de acesso são concedidos ao solicitante dos dados usando políticas que consistem em combinações lógicas de atributos. Os usuários devem estar cadastrados em um sistema central de IM, como Protocolo Leve de Acesso a Diretórios (*Lightweight Directory Access Pro-*

tolcol – LDAP) ou Diretórios Ativos (*Active Directory* – AD), para que cada usuário seja associado a atributos já definidos no sistema. Esses atributos podem incluir atributos de usuário, de recursos e de ambiente, como ilustrado na Figura 4.10. Os atributos de usuário incluem informações como nome, cargo, função, organização, dentre outras. As informações relativas ao atributo de recurso podem conter data de criação, nome do recursos que pode ser acessado, dentre outras. O atributo de ambiente pode incluir informações geográficas do recurso a ser acessado. As políticas, solicitações e respostas ABAC são expressas na linguagem XACML. Uma política é uma combinação de regras que o solicitante deve obedecer. Quando uma solicitação é emitida, as regras expressas nas políticas são avaliadas, explorando os valores dos atributos para retornar uma resposta. As respostas contêm a decisão sobre o pedido. Em diversos casos, a operação dos sistemas de EMR possui um alto grau de complexidade. Em função disso, é possível haver negligências no controle de acesso, podendo ser mais permissivo do que o necessário, o que pode representar ameaças para as informações do paciente [de Oliveira et al., 2023]. Em alguns cenários, utiliza-se o modelo ABAC para obter uma maior granularidade no acesso às informações do paciente. No entanto, seu uso em cenários reais de saúde continua sendo um desafio, principalmente em casos nos quais o fluxo de trabalho durante cuidados intensivos, por exemplo, requer o compartilhamento de dados entre organizações, sendo difícil a sua modelagem. Consequentemente, os modelos de controle de acesso existentes utilizando ABAC geralmente cobrem apenas situações de acesso convencionais deixando os cuidados intensivos sem a devida proteção de acesso [de Oliveira et al., 2023].

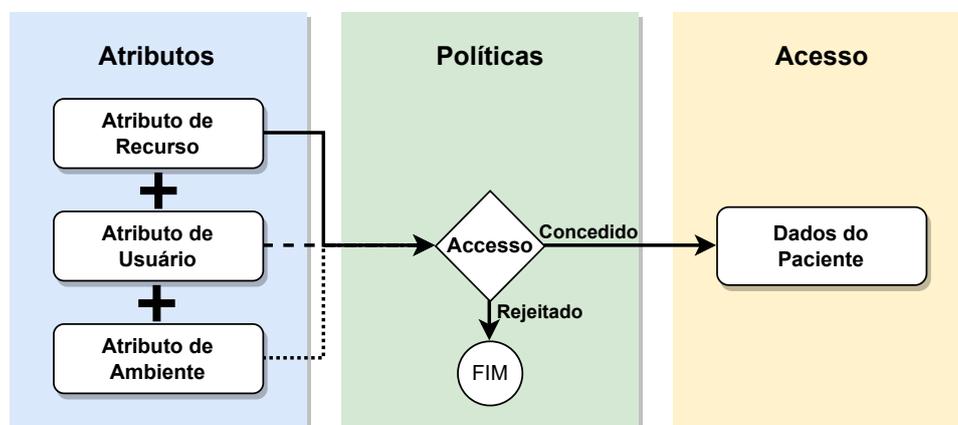


Figura 4.10. Modelo de controle de acesso baseado em atributos (ABAC). Existem basicamente três tipos de atributos, os de Recurso, os de Usuários e os de Ambiente. Os atributos associados a cada usuário diferenciam a permissão de acesso desses usuários. A combinação dos atributos executa uma política de permissão ou rejeição ao acesso.

Outra abordagem é o Controle de Acesso baseado em Propósito (*Purpose-based access control* – PBAC), que tem como objetivo relacionar os dados com finalidades específicas. Esse mecanismo aproveita as características do ABAC e RBAC, sendo capaz de utilizar tanto papéis como atributos. A ideia central desse modelo é conceder acesso mediante o entendimento prévio em que um dado pode ser coletado ou acessado. Os propósitos são organizados de forma hierárquica, através de princípios de generalização e especialização [Byun et al., 2005]. Esse fato pode contribuir significativamente para a

privacidade de dados sensíveis, embora o gerenciamento possa induzir uma maior complexidade em função do controle de cada propósito.

O padrão XACML define cinco componentes principais que lidam com decisões de acesso: *Policy Administration Point* (PAP), *Policy Enforcement Point* (PEP), *Policy Decision Point* (PDP), *Policy Information Point* (PIP) e *Context Handler* (CH). O PAP armazena e gerencia um conjunto persistente de políticas associadas aos identificadores de destino. O PEP constitui a integração para qualquer sistema, em que os recursos a serem protegidos são armazenados e gerenciados. O PEP recebe as solicitações de acesso e bloqueia o fluxo de execução até que uma decisão seja tomada. Ao mesmo tempo, o PEP propaga as solicitações para o PDP, que é o principal local de decisão para a solicitação de acesso recebida. O PDP recupera todos os atributos necessários e informações contextuais do PIP, avalia as políticas definidas e toma uma decisão de acordo com essas políticas. O PIP é responsável por recuperar e armazenar valores de atributos. O Context Handler (CH) é responsável por derivar o contexto de uma determinada solicitação. A Figura 4.11 exibe as diversas interações entre os componentes do padrão XACML, destacando a sequência cronológica das trocas de mensagens durante o processo de requisição de acesso. Antes de uma solicitação de acesso, é necessário que (1) o PAP escreva políticas e conjuntos de políticas e os torne disponíveis ao PDP. O solicitante do acesso (2) envia uma solicitação de acesso ao PEP, podendo incluir valores de atributos dos assuntos, recursos e ambiente. Os atributos de assuntos dizem respeito ao paciente na condição de emergência. Em seguida, (3) o PEP constrói um Contexto de requisição XACML padrão e o envia para o PDP, que (4) solicita quaisquer valores adicionais de atributo de assunto, de recurso e de ambiente do PIP. O PIP obtém os atributos solicitados e (5) os devolve ao PDP. Por sua vez, o PDP (6) solicita ao PAP as políticas de acordo com o objetivo do pedido. O PAP (7) retorna as políticas de solicitação para que o PDP (8) avalie a política relacionada e retorne o Contexto de Resposta XACML padrão para o PEP. Por fim, o PEP (9) executa a decisão de autorização, seja ela permitindo ou negando o acesso.

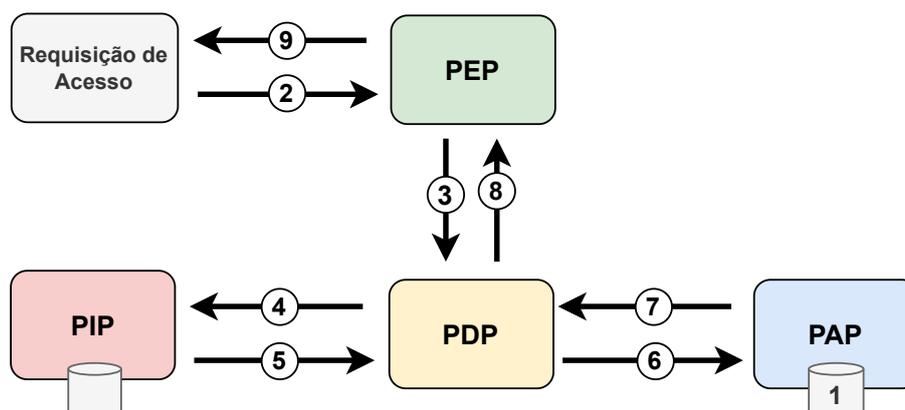


Figura 4.11. Arquitetura e fluxograma do padrão XACML. As interações entre os componentes do padrão XACML ocorrem em ordem cronológica, devendo haver uma definição de políticas para que a consulta possa ser realizada resultando em permissão ou negação de acesso aos dados solicitados.

4.4.2. Normas e legislações para proteção de dados

Políticas de proteção de dados privados, cada vez mais severas, impõem limites para abordagens centralizadas de processamento de dados. As leis de proteção de dados pessoais estipulam direitos aos titulares dos dados e obrigações às instituições que detêm tais dados. Uma lei de destaque é o Regulamento Geral de Proteção de Dados (*General Data Protection Regulation* – GDPR)²³, vigente em toda a União Europeia (UE), que estabelece diretrizes quanto ao tratamento, por uma pessoa, empresa ou organização, dos dados pessoais de todos na União Europeia. Para cumprimento da lei, é essencial realizar previamente o processo de identificação de dados sensíveis. Isso envolve diversas etapas para garantir que os dados pessoais nos armazenamentos de dados da organização sejam tratados adequadamente. A etapa inicial é descobrir e localizar dados pessoais nos repositórios de dados da organização. Uma vez identificados, os dados são categorizados com base em sua natureza e sensibilidade. Posteriormente, são implementadas medidas adequadas para proteger os dados sensíveis identificados.

Cada categoria de dados confidenciais pode ter requisitos de privacidade específicos, como criptografia, tempo de custódia, segurança física e lógica. A GDPR define categorias especiais, como dados raciais e de saúde. Ao lidar com essas categorias, uma empresa deve ter uma base válida e legal para coletar, armazenar, transmitir ou processar os dados. Além disso, podem ser aplicadas salvaguardas e considerações mais rígidas para garantir a privacidade e a segurança dessas categorias especiais de dados [Larrucea et al., 2020]. Um dos principais desafios no tratamento de registros médicos eletrônicos é o fato de a GDPR enfatizar a necessidade de consentimento por parte dos paciente para manipulação dos dados. Os requisitos fundamentais para eficácia desse consentimento são definidos no artigo 7º da GDPR, o qual especifica que quando o processamento for baseado no consentimento, o controlador dos dados deve ser capaz de demonstrar que o titular dos dados consentiu o tratamento de seus dados pessoais. Além disso, ao avaliar que tal consentimento é fornecido de maneira espontânea, a execução de um contrato, incluindo a prestação de um serviço, está condicionada ao consentimento para o processamento de dados pessoais que não são necessários para a execução daquele contrato. Tradicionalmente, os contratos e consentimentos são efetuados através de documentos impressos ou digitais. Esses documentos possuem complexidade desde a geração, manipulação e armazenamento, tanto do ponto de vista logístico quanto de segurança. Nesse sentido, abordagens utilizando contratos inteligentes distribuídos podem ser considerados fundamentais na transição para um mundo completamente digital.

No caso do Brasil, a Lei Geral de Proteção de Dados (LGPD) promulgada em 2018, é uma lei federal responsável pela proteção de dados em todo território nacional. Similar à GDPR, a LGPD se aplica a qualquer organização que processe dados pessoais no Brasil, independentemente de estar sediada ou não em território nacional. A lei define dados pessoais de forma ampla, como qualquer informação relacionada a uma pessoa natural ou pessoa jurídica de direito público ou privado. Entende-se por informações pessoais nome, endereço, e-mail, número de telefone, número de identificação, endereço IP, entre outras. A lei identifica como agentes de tratamento a pessoa natural ou jurídica de direito público ou privado que realiza qualquer operação de tratamento sobre os dados

²³Disponível em <https://gdpr-info.eu/>.

peçoais de outrem. Dentre os deveres estabelecidos a esses agentes estão a coleta de consentimento explícito do titular do dado e a disponibilização de relatórios que identifiquem as operações de tratamento aplicadas ao dado, incluindo a especificação de seu local de armazenamento, mascaramento do dado e medidas de proteção. Diversas organizações devem implementar medidas técnicas e organizacionais para garantir a segurança e confidencialidade dos dados pessoais, devendo relatar quaisquer violações de dados à Autoridade Nacional de Proteção de Dados (ANPD) e aos indivíduos afetados. A ANPD é responsável por policiar o cumprimento da LGPD, impondo multas e penalidade.

Pela LGPD, os dados de saúde são considerados dados pessoais sensíveis e seu processamento está sujeito a regras específicas. Assim como a GDPR, o tratamento dos dados sensíveis exige o consentimento por parte do titular ou seu responsável legal, de forma específica e destacada, para finalidades específicas²⁴. Outro documento comumente utilizado é o Termo de Consentimento Livre e Esclarecido (TCLE). Esse documento é assinado pelo paciente ou seu responsável legal, com o objetivo de esclarecer dúvidas acerca das possíveis intercorrências, riscos envolvidos ou outras informações pertinentes a um determinado tratamento ou procedimento médico. Por possuir informações sensíveis, os dados presentes nesse documento também são regidos pela LGPD. Na maioria dos casos, esse termo é preenchido e assinado manualmente, o que pode dificultar o sigilo das informações nele contidas. Embora haja uma migração cada vez maior para a digitalização desses dados, existem diversos problemas a serem resolvidos. Um dos principais desafios encontrados no Brasil referente ao acesso aos dados digitalizados, é a carência de acesso à Internet em áreas periféricas das grandes cidades e também em áreas rurais. Esse fato implica diretamente os pacientes, uma vez que sem acesso à Internet ficariam impedidos de acessar seus registros médicos. Outro desafio, é o fato de não haver no Brasil, legislação específica para tratamento de registros médicos eletrônicos, diferentemente dos Estados Unidos que possui a Lei de Portabilidade e Responsabilidade de Seguro Saúde (*Health Insurance Portability and Accountability Act – HIPPA*).

Diferentemente da GDPR e LGPD, que são leis gerais para dados pessoais, a HIPAA é uma legislação dos Estados Unidos, promulgada em 1996, criada especificamente para proteção das informações de saúde dos indivíduos. Ela estabelece padrões de privacidade e segurança para as informações médicas, conhecidas como informações de saúde protegidas (*Protected Health Information – PHI*) e restringe o acesso e a divulgação desses dados por parte dos profissionais de saúde, provedores de serviços médicos e empresas de seguros. Existem ainda, diretrizes de privacidade para definir os termos relacionados aos direitos e os limites de privacidade dos pacientes, para que possam compreender e controlar seus dados [Lee et al., 2021]. Essas diretrizes utilizam sete termos principais:

- **Compreensão dos pacientes:** Os pacientes possuem o direito de compreender os procedimentos para armazenar, utilizar e reter suas informações de saúde pelos profissionais de saúde;
- **Confidencialidade:** Os dados de saúde são protegidos durante o armazenamento e transmissão utilizando técnicas como criptografia, autenticação. Sob nenhuma

²⁴Disponível em https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/113709.htm

circunstância os dados de saúde do paciente devem ser divulgados a terceiros sem prévia autorização;

- **Controle dos pacientes:** Os pacientes devem ter a capacidade de controlar e autorizar quem pode acessar e utilizar seus dados de saúde;
- **Integridade dos dados:** As informações eletrônicas de saúde dos pacientes devem ser protegidas contra modificações ou destruição não autorizadas;
- **Exceção de consentimento:** Em situações excepcionais em que um paciente corre risco de vida ou em outras circunstâncias críticas, as informações de saúde podem ser divulgadas e usadas sem a autorização individual do paciente;
- **Não-repúdio:** Para garantir que as autoridades responsáveis cumpram suas obrigações em relação às informações dos pacientes, quaisquer atividades relevantes devem ser apoiadas por evidências verificáveis;
- **Auditoria:** O monitoramento regular das informações de saúde dos pacientes e o registro abrangente das atividades relacionadas são necessários para garantir a segurança dos dados. Os pacientes devem receber garantias quanto à segurança e proteção de suas informações de saúde.

A ideia central do tratamento de privacidade da HIPAA é garantir que as informações de saúde dos indivíduos sejam devidamente protegidas, permitindo o fluxo de informações de saúde necessárias para fornecer e promover cuidados de saúde. A HIPAA estabelece um equilíbrio que permite a utilização de informações importantes, ao mesmo tempo em que protege a privacidade das pessoas que buscam atendimento. Existe um vasto mercado de saúde nos Estados Unidos, amplamente diversificado e a regulamentação HIPAA é projetada para que seja flexível e abrangente, permitindo cobrir uma variedade de usos e divulgações que precisam ser abordadas²⁵. Outro aspecto importante da HIPAA é a maneira que aborda casos de violações de informações de saúde. Segundo a regulamentação, uma violação geralmente ocorre através do uso ou divulgação não autorizada sob a “Regra de Privacidade” que compromete a segurança ou a privacidade das informações de saúde protegidas. A “Regra de Privacidade” estipula padrões para proteção dos registros médicos dos indivíduos e outras informações de saúde, passíveis de identificação individual. Essa regra exige a guarda adequada das informações de modo a garantir a privacidade de dados protegidos, além de garantir o direito de examinar e obter uma cópia de seus registros de saúde. Pressupõe-se que o uso ou a divulgação não autorizados de informações de saúde protegidas seja uma violação, a menos que a entidade coberta (planos de saúde, hospitais e clínicas) ou parceiro comercial demonstre que há uma baixa probabilidade de que as informações de saúde confidenciais tenham sido comprometidas com base em uma avaliação de risco. Há ainda três exceções no que diz respeito à definição de violação. A primeira exceção se aplica à aquisição, acesso ou uso não intencional de informações de saúde protegidas por um membro da força de trabalho ou pessoa agindo sob a autoridade de uma entidade coberta ou parceiro comercial, se tal

²⁵Disponível em <https://www.hhs.gov/hipaa/for-professionals/privacy/laws-regulations/index.html>.

aquisição, acesso ou uso foi feito de boa fé e dentro o alcance da autoridade. A segunda exceção se aplica à divulgação inadvertida de informações de saúde protegidas por uma pessoa autorizada a acessar tais informações em uma entidade ou parceiro comercial coberto para outra pessoa autorizada a acessar essas informações na entidade ou parceiro comercial ou organização de assistência médica. Em ambos os casos, as informações não podem ser usadas ou divulgadas sem a devida autorização mediada pela “Regra de Privacidade”. A terceira exceção se aplica à entidade coberta ou ao parceiro comercial acreditar de boa fé que a pessoa não autorizada, a quem a divulgação sem autorização foi feita, não seria capaz de reter as informações²⁶.

4.5. Soluções para Integração e Compartilhamento Seguro de Dados de Saúde

A integração e o compartilhamento seguro de dados de saúde são temas fundamentais para a evolução dos sistemas de saúde. O avanço da tecnologia e a digitalização dos registros médicos originam diversos desafios relacionados à interoperabilidade e à proteção da privacidade dos pacientes. Os dados dos pacientes estão pulverizados em diversos silos de dados que não se comunicam e não utilizam necessariamente o mesmo padrão de representação e comunicação, o que dificulta a troca de informações de forma eficiente e segura. Mesmo que seja possível a troca de informação, o compartilhamento de informações sensíveis requer medidas robustas de proteção, como criptografia e controle de acesso, para garantir que apenas pessoas autorizadas tenham acesso aos dados e que a integridade desses dados seja preservada. Assim, a falta de padronização, a diversidade de sistemas, a segurança dos dados e questões regulatórias tornam a integração e o compartilhamento seguro um aspecto complexo na área de saúde. Diversas soluções têm sido desenvolvidas para enfrentar essas questões, visando melhorar a qualidade do atendimento, facilitar a troca de informações entre profissionais e garantir a segurança dos dados sensíveis. Nesse contexto, exploram-se algumas das soluções disponíveis no mercado e propostas na literatura para promover a integração e o compartilhamento seguro de dados de saúde.

4.5.1. Abordagens Tradicionais

Tradicionalmente, a segurança dos dados nos estabelecimentos de saúde é garantida por meio do uso de sistemas de acesso restrito, protegidos por *firewalls*, com normas rígidas relativas à amplitude e quantidade de dados de paciente que podem ser arquivados. Mais recentemente, protocolos de criptografia foram aplicados.

O sistema eletrônico **e-SUS Atenção Primária (APS)**²⁷ reúne diversas ferramentas voltadas para a reformulação da Atenção Básica (AB) a fim de informatizar o Sistema Único de Saúde (SUS). Atualmente, o e-SUS é composto por dois sistemas de *software* complementares, capazes de instrumentalizar o processo de coleta de dados médicos. O Prontuário Eletrônico do Cidadão (PEC) foca o armazenamento de todas as informações clínicas e administrativas do paciente, no contexto da Unidade Básica de Saúde (UBS),

²⁶Disponível em <https://www.hhs.gov/hipaa/for-professionals/breach-notification/index.html>.

²⁷Disponível em <https://sisaps.saude.gov.br/esus/>.

isto é, qualquer estabelecimento de saúde enquadrado como posto de saúde, centro de saúde básica, unidades mistas ou centro de apoio à saúde da família. O *software* de Coleta de Dados Simplificada (CDS) dedica-se exclusivamente a estruturar a digitação do cadastro e das fichas de atendimento, sendo especialmente adaptado para cenários sem informatização ou com conectividade limitada, instável ou inexistente. Para tal, a inserção de dados no CDS pode ser realizada de maneira *off-line* e posteriormente consolidada através de um PEC com conectividade. A simplicidade do CDS acarreta uma limitação na capacidade de armazenamento local no banco de dados embarcado, além de inviabilizar funções gerenciais.

Independentemente do *software* de coleta utilizado, os dados são encaminhados ao Sistema de Informação em Saúde para a Atenção Básica (SISAB), responsável pela centralização nacional do processamento e pela disseminação de dados e informações relacionadas à AB. Antes de serem disponibilizados no sistema, os dados enviados são submetidos a um processo de validação a fim de verificar a originalidade, o cumprimento de critérios temporais e o vínculo com um estabelecimento registrado no Cadastro Nacional de Estabelecimentos de Saúde (CNES). Com base nos dados consolidados, o SISAB emite relatórios de desempenho contendo indicadores de saúde por estado, município, região de saúde e equipe. O controle de acesso aos recursos dentro do e-SUS é baseado em perfis de acesso, ou papéis, em que cada perfil é associado a um conjunto de recursos do sistema que podem estar ativos ou inativos, dependendo das atividades desenvolvidas pelo profissional. A integração com sistemas terceirizados é viabilizada através da API do *Apache Thrift* ou adotando arquivos padronizados no formato XML. Dessa forma, o sistema já existente em uma unidade de saúde deve ser capaz de gerar arquivos Thrift/XML, que são importados para o PEC municipal. O PEC é capaz de gerar relatórios de inconsistências e controlar a transmissão dos dados para o SISAB por meio de um sistema centralizador nacional. Ambas as alternativas, Thrift ou XML, garantem a interoperabilidade do e-SUS APS com sistemas já implementados em municípios, permitindo a importação dos dados coletados e a consolidação no SISAB.

A plataforma AGHUX (Aplicativo de Gestão para Hospitais Universitários)²⁸ tem como foco a gestão de hospitais universitários e auxilia a padronização das práticas assistenciais e administrativas desses hospitais. O sistema é desenvolvido pela Empresa Brasileira de Serviços Hospitalares (EBSERH) e prevê o acesso unificado a todos os registros eletrônicos de saúde gerados pelos hospitais integrantes da rede. Essa integração proporciona uma visão transversal sobre a trajetória clínica do paciente, aprimorando a continuidade de tratamentos e atendimentos independente do hospital de origem. O acesso remoto às informações médicas registradas no AGHUX é viabilizada através do HU Digital²⁹, uma plataforma digital disponível tanto no formato *web* quanto por meio de aplicativos em dispositivos móveis. O HU Digital oferece interfaces distintas dependendo se o perfil de usuário que o acessa é um profissional de saúde ou um paciente. Os pacientes têm acesso aos próprios históricos de dados, além de usufruir de serviços digitais, como emissão de certificados e realização de teleconsultas. Atualmente, a permissão de acesso pode ser concedida a pessoas físicas ou a hospitais universitários específicos

²⁸Disponível em <https://www.gov.br/ebserh/pt-br/hospitais-universitarios/regiao-centro-oeste/hujm-ufmt/governanca/aghux>

²⁹Disponível em <https://hudigital.ebserh.gov.br/>

da rede. Analogamente, médicos e enfermeiros devidamente autorizados podem se autenticar no HU Digital a fim de consultar sumários de alta, procedimentos e cirurgias realizadas ou agendadas.

A Figura 4.12 destaca os módulos que compõem o AGHUX. Os módulos são dedicados a funções administrativas e a procedimentos médicos. O módulo Pacientes lida com o cadastramento dos pacientes no sistema, subsidiando as demais atividades de atendimento. Dependendo do procedimento realizado no hospital, pode-se realizar a abertura de prontuário. Através do módulo Prontuário *On-Line* (POL) são visualizadas todas as informações clínicas do paciente, contemplando seu histórico de registros de atendimentos realizados. O módulo Ambulatório Administrativo é acionado em situações que exijam procedimentos simples como realização de curativos, pequenas cirurgias, primeiros socorros. O módulo Ambulatório Assistencial permite ao médico analisar a evolução do atendimento dentro do consultório. O módulo Internação apoia a gestão das internações hospitalares, com funcionalidades de admissão, gestão de leitos, atribuição dos profissionais responsáveis, emissão de sumário de alta e realização de alta médica e administrativa. O módulo Prescrição de Enfermagem auxilia na definição dos cuidados aplicados a cada paciente, com base nos dados coletados e analisados e do diagnóstico estabelecido pela equipe de enfermagem. O módulo Controle de Paciente visa informatizar os registros dos controles do paciente, abrangendo os processos de monitorizações e controle hídrico, permitindo agilidade na visualização da informação e maior segurança na assistência ao paciente. O módulo Prescrição Médica registra os diagnósticos e as prescrições médicas, gerando condutas e atividades para a equipe assistencial. O módulo Exames consolida os registros de Serviços de Apoio ao Diagnóstico e Terapêutico (SADT) em um conjunto organizado de elementos, incluindo solicitações, acompanhamento e resultados. O módulo Farmácia compreende o processo de gestão dos medicamentos, incluindo atividades de regulação, triagem e dispensação. Intimamente atrelado ao anterior, o módulo Estoque concentra-se em gerenciar as movimentações dos suprimentos através do controle do fluxo de materiais, proporcionando um eficaz atendimento das solicitações de materiais. O módulo Cirurgia detalha quaisquer ações relacionadas a procedimentos cirúrgicos complexos, tais como descrição do procedimento, agendamento de sala, medição do tempo de utilização e cálculo de custos. Devido à modularidade do sistema, o principal desafio enfrentado pelo AGHUX é o descompasso entre as versões do sistema implantadas nos hospitais universitários e a implantação dos módulos, que podem não ser compatíveis com a versão do sistema existente no hospital.

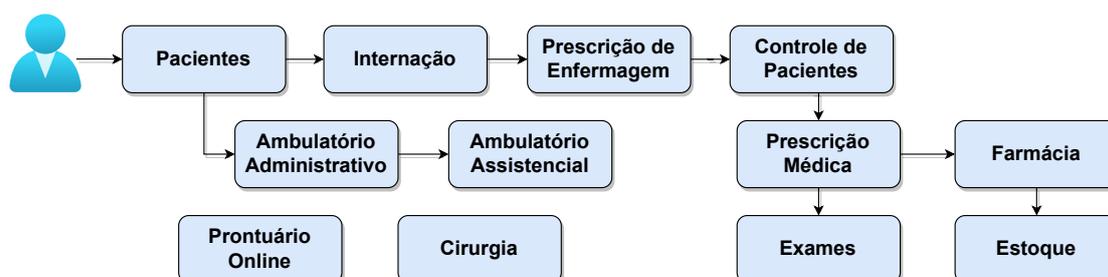


Figura 4.12. Visão geral dos módulos integrantes do sistema AGHUX e interação entre esses módulos.

Algumas soluções disponíveis comercialmente têm como foco áreas específicas da saúde, como o **iDoc**³⁰, criado para radiologia odontológica. O iDoc é uma plataforma para distribuição *online* de exames e diagnósticos, que reúne dados e exames dos pacientes enviados por diferentes clínicas radiológicas. Assim, o iDoc centraliza as informações dos pacientes, permitindo que o dentista tenha acesso aos dados dos pacientes mesmo que os exames tenham sido realizados em clínicas diferentes. O dentista pode também adicionar informações sobre o paciente, incluindo o histórico e a anamnese. A plataforma dispensa o uso de exames impressos, permitindo o compartilhamento *online* dos exames digitais, que são armazenados em nuvem. O iDoc tem capacidade de hospedar arquivos digitais em formatos como JPEG, DICOM, STL, PLY, PPTZ, DOCX e PDF³¹. A plataforma tem como vantagem a rapidez e a agilidade com que o exame fica disponível para consulta. Assim que o exame é finalizado, a clínica pode enviá-lo ao dentista. A plataforma também oferece uma variedade de recursos, como uma ferramenta de modelo digital que permite analisar a arcada dentária do paciente em formato tridimensional. Não há informações disponíveis sobre como o controle de acesso aos dados é realizado.

Outro sistema comercial é o **Alert**³², adaptado para *web* e nuvem. O Alert é destinado ao gerenciamento completo do processo clínico eletrônico por meio de diversos produtos que compõem a solução. Inclui diversas funcionalidades para o acompanhamento do histórico de cada paciente, agendamento e alertas de consultas ou procedimentos médicos, atribuição de altas, emissão de relatórios, teleatendimento e gestão de pedidos. Além disso, o *software* dispõe de um sistema interno de planejamento e de inteligência empresarial. A solução utiliza padrões de interoperabilidade e suporte IHE, HL7 e ITIL, e terminologias internacionais, como SNOMED, ICD, LOINC, dentre outras. O acesso aos diversos produtos é feito por meio de um mecanismo *Single Sign-On* (SSO) que fornece aos usuários um esquema de autenticação centralizada em todo o domínio das aplicações Alert. O SSO suporta a integração dos produtos Alert com domínios LDAP ou AD. O acesso aos dados dos pacientes é feito com base em perfis pré-definidos associados a cada profissional cadastrado no sistema.

O **GestãoDS** é um *software* médico com agendamento *online*, controle financeiro, telemedicina, *marketing* médico e outras funcionalidades criadas para facilitar a gestão de clínicas e consultórios. O *software* também oferece assinatura digital e garante privacidade dos dados no processamento, na manutenção e no armazenamento de informações relacionadas à saúde em conformidade com a HIPAA. A solução fornece vários níveis de permissão de acesso, separados em perfis de usuários. Além disso, oferece modelos personalizados de prontuários e prescrições de acordo com o padrão de atendimento do profissional.

4.5.2. Abordagens baseadas em cadeia de blocos

A incorporação da tecnologia de cadeia de blocos em diversas aplicações tem sido amplamente motivada pela possibilidade de gerar evidências computacionais irrefutáveis, armazenadas de forma distribuída, da ordem cronológica das transações realizadas. Esses benefícios são desejáveis em soluções de compartilhamento de EMRs, visto que há

³⁰Disponível em <https://idoc.radiomemory.com.br/>

³¹Disponível em <https://blog.radiomemory.com.br/conheca-o-idoc-academico/>

³²Disponível em <https://www.alert-online.com/br/>

necessidade de rastreabilidades dos dados acessados. Nesse sentido, diversas soluções baseadas em cadeia de blocos são propostas na literatura, sendo algumas delas disponibilizadas comercialmente. Dentro do âmbito comercial, a plataforma **Medicalchain**³³ constitui-se como um mercado de dados de saúde acessado por MedTokens. Quinhentos milhões de MedTokens foram emitidos e vendidos em 2018. Nessa solução, o paciente controla o acesso dos médicos aos registros, por exemplo, durante uma consulta de telemedicina, e podem conceder a pesquisadores acesso aos registros em troca de MedTokens. Os MedTokens também podem ser usados para pagar consultas médicas [Albeyatt, 2018]. A solução é construída com base em duas cadeias de blocos e não armazena dados médicos nos blocos. A primeira é usada para controlar o acesso aos EMRs e é implementada utilizando a plataforma Hyperledger Fabric. A segunda cadeia é usada para geração dos *tokens*, o que é feito por meio do Pedido de Comentários Ethereum 20 (*Ethereum Request for Comments 20 – ERC20*)³⁴ da Ethereum. A distribuição do *token* é controlada por um contrato inteligente. Assim, a Ethereum é usada para pagamentos. Semelhante à Medicalchain, a solução **MedChain** usa dois tipos de *tokens* distintos: *tokens* externos, denominados MedCoins, para fornecer controle de acesso e privacidade; e *tokens* internos, denominados *Record Tokens*, para fornecer um mapa do registro do paciente distribuído, adicionando resumos criptográficos à cadeia de blocos [Sandgaard e Wishstar, 2018]. A plataforma de cadeia de blocos utilizada é a Ethereum para ancoragem de verificação e a Hyperledger Fabric. Os registros na MedChain podem incluir dados de saúde em vários formatos, como texto simples, imagens digitais ou objetos de banco de dados. Essas informações são armazenadas em um sistema de arquivos distribuído com base no Sistema de Arquivos Interplanetário (*InterPlanetary File System – IPFS*). O endereço do registro de um paciente armazenado no sistema de arquivos é associado ao “bloco de paciente” daquele paciente na Ethereum. Para recuperar todos os registros do paciente, há interação com um contrato inteligente para obtenção de todos os endereços de todos os registros do paciente. Ao obter os endereços, é possível utilizá-los para solicitar cada registro ao IPFS. Outras soluções como a **MediBChain**, fornecem privacidade [Al Omar et al., 2017] e protegem a identidade do paciente utilizando o pseudonimato através de chaves públicas criptográficas. A proposta implementa um sistema de gerenciamento de dados de saúde centrado no paciente baseado em cadeia de blocos permissionada. Não há informação sobre a plataforma utilizada.

Dentre as soluções acadêmicas, a proposta **AuditChain** fornece controle de acesso multinível para pacientes, médicos, enfermeiros e administradores hospitalares para o gerenciamento de EMRs [Anderson, 2018]. A proposta implementa contratos inteligentes utilizando a plataforma Hyperledger Fabric [Rebello et al., 2019; Agrawal et al., 2022]. A assinatura digital da transação usa criptografia de chave pública e serve como um *token* virtual para controle de acesso. A proposta **Medblock** [Fan et al., 2018] implementa uma estrutura de compartilhamento de dados com um mecanismo de controle de acesso baseado em um esquema de assinatura. Os dados confidenciais e os ponteiros para o EMR do paciente são criptografados com um esquema de assinatura múltipla dentro da cadeia de blocos. O mecanismo de controle de acesso percorre os blocos até encontrar o bloco correto comparando a assinatura com a coleção de assinaturas no livro-razão. A permissão

³³Disponível em <https://medicalchain.com/en/>

³⁴Padrão de *Fungible Token* que implementa uma API para *tokens* em contratos inteligentes.

para ver o conteúdo criptografado no bloco depende do resultado da comparação. Zhang *et al.* propõem o **FHIRChain** para compartilhamento de dados entre médicos e pesquisadores com base no padrão FHIR [Zhang et al., 2018]. O FHIRChain atende a cinco requisitos principais de interoperabilidade: identificação e autenticação do usuário, troca segura de dados, acesso autorizado a dados, formatos de dados consistentes e modularidade do sistema. O controle de acesso aos dados é baseado em um contrato inteligente que resulta em um *token* de acesso e executa na plataforma Ethereum. Os *tokens* de acesso são definidos para cada transação de dados, que usa criptografia assimétrica para proteger os ponteiros de dados fora da cadeia. A proposta usa as identidades digitais de saúde dos usuários para criptografar o conteúdo, de modo que apenas os usuários que possuem as chaves privadas de identidade digital corretas possam descriptografar o conteúdo. Dagher *et al.* propõem a **Ancile**, uma cadeia de blocos baseada em Ethereum para um sistema de gerenciamento de registros que utiliza contratos inteligentes para maior controle de acesso e ofuscação de dados [Dagher et al., 2018]. A Ancile mantém os registros médicos dos pacientes nos bancos de dados existentes dos provedores e os endereços de referência a esses registros e suas permissões para cada registro são armazenados no contrato inteligente. A Ancile foi projetada para armazenar os endereços Ethereum de todos os nós que podem interagir com um registro, um nível de acesso e uma chave simétrica criptografada com a chave pública de cada nó. Em contrapartida, Oliveira *et al.* desenvolvem uma abordagem de distribuição de EMR cujo controle de acesso é centrado no paciente [de Oliveira et al., 2019]. A abordagem depende de uma infraestrutura de chave pública (*Public Key Infrastructure* – PKI) e da tecnologia cadeia de blocos. A ideia é herdar a confiança na autenticidade fornecida pela PKI e a integridade e a responsabilização fornecidas pela cadeia de blocos. A proposta é um EMR distribuído, com infraestrutura computacionalmente simples, controle de acesso refinado e baixa sobrecarga.

Rouhani *et al.* propõem um sistema ABAC para compartilhamento de dados EMR [Rouhani et al., 2021], ao passo que Maesa *et al.* propõem um sistema ABAC usando a plataforma de cadeia de blocos Ethereum [Maesa et al., 2019]. Ao optarem pelo armazenamento dos valores dos atributos na cadeia de blocos, os valores não podem ser alterados devido à propriedade de imutabilidade. Em compensação, os valores são auditáveis, visto que suas atualizações podem ser executadas apenas por meio de transações e assim registradas na cadeia de blocos. Não obstante, ambas as propostas não consideram que os atributos devam ser autenticados pelas organizações do processador do dado sempre que interagem com o sistema de controle de acesso. Por ser um sistema assíncrono, a cadeia de blocos exige que as organizações atualizem continuamente os atributos de seus profissionais na cadeia de blocos, fato que onera atributos dinâmicos dos profissionais de saúde. Por outro lado, Ghorbel *et al.* propõem manter os atributos do usuário fora da cadeia de blocos (*off-chain*) e confiar nas autoridades confiáveis para manter uma lista de usuários associados aos seus atributos verificados [Ghorbel et al., 2021]. Empregando um contrato inteligente, essas autoridades autenticam os atributos do usuário durante a solicitação de dados do usuário. Os autores utilizam a plataforma Quorum, que implementa uma versão permissionada da cadeia de blocos Ethereum. Internamente, a plataforma Quorum adota um mecanismo de consenso flexível, capaz de suportar o consenso RAFT para tolerância a falhas de travamento e variações do PBFT para tolerância a falhas bizantinas.

Ao associar a tecnologia de cadeia de blocos e um esquema de assinatura baseado em atributos sobre múltiplas autoridades, Guo *et al.* propõem um sistema de EMR distribuído [Guo et al., 2018] que permite ao paciente gerenciar com segurança Registros Pessoais de Saúde (*Personal Health Record* - PHR). No entanto, essa facilidade também traz um custo de desempenho, pois cria uma sobrecarga para assinar a transação por várias autoridades. A proposta também sofre de questões de confidencialidade relativas aos dados armazenados na cadeia de blocos. De maneira semelhante, Dang *et al.* analisam o uso da computação em névoa para armazenar e proteger EMRs e usam assinaturas baseadas em atributos para garantir privacidade e confidencialidade de EMR em ambientes de névoa e nuvem [Dang et al., 2018]. Por sua vez, Yue *et al.* concentram-se em fornecer um controle de privacidade refinado [Yue et al., 2016]. O sistema proposto usa telefones celulares para interagir com um *gateway* de controle de acesso que controla o acesso aos blocos na cadeia de blocos. No entanto, o *gateway* não controla as transações. Daraghmi *et al.* propõem um mecanismo de consenso baseado em incentivo que alavanca o grau de reputação dos provedores de saúde em relação aos seus esforços na manutenção de registros médicos e na criação de novos blocos na cadeia de blocos [Daraghmi et al., 2019]. O contrato de controle de acesso inclui todas as informações relacionadas às permissões específicas para cada registro baseado em contratos inteligentes. A proposta lista os endereços da cadeia de blocos Ethereum para todos os usuários que têm permissões de acesso ao registro. O contrato especifica o nível de acesso e a chave simétrica criptografada com a chave pública de cada usuário.

No Brasil, existe uma solução governamental notória para compartilhamento de dados de saúde em rede nacional, a RNDS³⁵ (Rede Nacional de Dados em Saúde). A RNDS é uma plataforma de integração desenvolvida pelo DataSUS e pela Secretaria Executiva do Ministério da Saúde. Quando integralmente consolidada, a RDNS pretende incluir um repositório de informações retrospectivas, simultâneas e prospectivas do paciente em formato digital. Sua utilização permitirá que inúmeros estabelecimentos compartilhem informações transversais de atendimento do cidadão de forma integrada, contínua, eficiente e de qualidade. Para simplificar a interoperabilidade dos prontuários do cidadão, a RNDS prevê que o histórico de registros médicos do paciente seja disponibilizado em uma estrutura de cadeia de blocos compartilhada entre os estados. A arquitetura da plataforma é apresentada na Figura 4.5.2. A plataforma conta com uma infraestrutura hospedada em nuvem com contêineres dedicados e distribuídos para os estados federados. Cada contêiner é subdividido em serviços informacionais e serviços tecnológicos, classificados tanto de acordo com o tipo, por exemplo, conjunto mínimo de dados ou relacionados à segurança, quanto conforme o grau de maturidade de desenvolvimento do serviço, como disponíveis ou planejados [Santos et al., 2022].

Os serviços tecnológicos disponíveis incluem o **Master Patient Index** (MPI), um banco de dados que atua unificando as informações de cada paciente registrado por uma organização de saúde. Sendo um padrão de projeto de *software*, o **Backend For Frontend** (BFF) é responsável pela entrega de como as informações serão armazenadas e consultadas, independentemente das especificidades de cada tipo de interface gráfica, por exemplo, aplicativo e portal *web*. Os **Serviços Eletrônicos de Saúde** (*EHR-Service*)

³⁵Disponível em <https://www.gov.br/saude/pt-br/assuntos/rnds>.

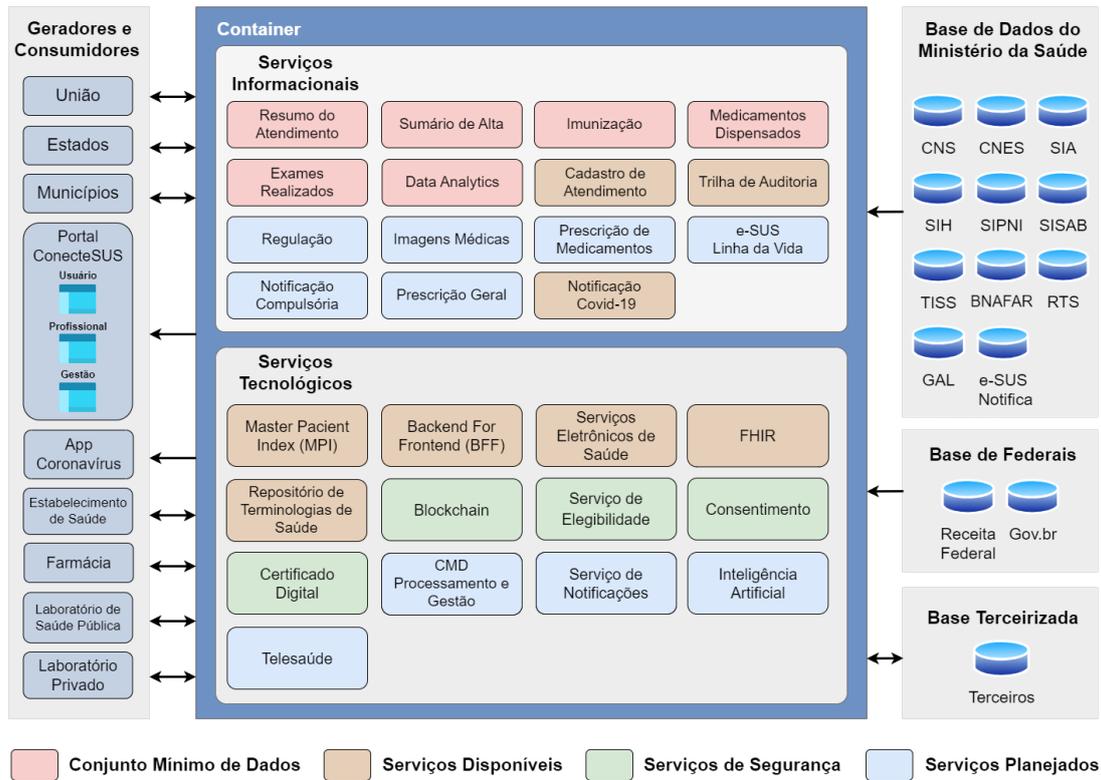


Figura 4.13. A RNDS é uma solução governamental para integração de sistemas de saúde e compartilhamento de dados de saúde em território nacional. A plataforma ainda está em desenvolvimento e conta com diversos módulos ainda não implementados.

concentram os serviços RESTful na troca de informações entre as aplicações de Saúde Digital, em especial o PEC, portais e aplicações *web*. O padrão **FHIR** auxilia na troca de informações de saúde entre diferentes estabelecimentos e instituições. O **Repositório de Terminologias em Saúde** é um ambiente virtual nacional que abriga classificações, nomenclaturas, terminologias, taxonomias, modelos de informação e definições comuns necessárias para a padronização de recursos semânticos e modelos de informação a serem utilizados no setor de saúde [Santos et al., 2022].

Dentre os serviços tecnológicos de segurança, o mais relevante é o relacionado à tecnologia de cadeia de blocos. A RNDS prevê a implementação de uma cadeia de blocos privada e permissionada, baseada em Hyperledger Fabric, e executando o mecanismo de consenso Raft [Tribunal de Contas da União (TCU), 2020]. Cada contêiner representa um nó de cadeia de blocos e estará localizado em um estabelecimento de saúde. A adoção da cadeia de blocos visa o armazenamento do histórico de interações entre pacientes e profissionais de saúde além de conter referências para os registros de saúde eletrônicos. Atualmente, a cadeia de blocos da RNDS possui apenas um nó, o que não garante as propriedades características da tecnologia. O processo de recuperação dos dados de saúde de qualquer paciente via cadeia de blocos, precisa satisfazer algumas premissas: (i) a requisição de acesso deve ser originada de uma ferramenta de *software* apropriada; e (ii) o solicitante deve integrar um estabelecimento cadastrado no CNES e deve possuir credenciais corretas. Caso um profissional requirite o acesso a qualquer documento ou

registro médico do paciente, somente é atendido mediante o consentimento e autorização explícita do paciente, ou em circunstâncias médicas emergenciais, ou quando configurada a estratégia “*opt out*” no contexto de atendimento no estabelecimento de saúde. A estratégia “*opt out*” assume de antemão que o paciente autoriza a flexibilização das regras de acesso aos seus dados. Assim, caso deseje alterar a política de permissão, o paciente poderá fazê-lo mediante à solicitação [Tribunal de Contas da União (TCU), 2020]. Internamente, os metadados são utilizados no livro-razão e distribuídos entre os diversos participantes da rede. Os documentos clínicos serão utilizados em uma coleção de dados privados (*private data collection*), um recurso nativo da Hyperledger Fabric, que permite que um subconjunto definido de organizações consiga endossar, confirmar ou consultar dados privados sem a necessidade de criar um canal separado. Esse recurso garante a privacidade e economicidade de armazenamento do documento. Uma vez que os documentos serão armazenados apenas na organização custodiante e em uma estrutura limitada de organizações de *backup*, não haverá eventual armazenamento excessivo dos documentos clínicos. Como é compartilhado no livro-razão, o histórico do paciente estará acessível para qualquer organização, o que facilitará as consultas dos pacientes nos estabelecimentos de saúde. A interoperabilidade entre sistemas é assegurada pela adoção do padrão FHIR e terminologia LOINC para o tráfego e armazenamento dos dados. Inicialmente, a RNDS prevê a utilização de microsserviços de transição, capazes de realizar a conversão dos dados enviados em CDA, OpenEHR e FHIR. Para evitar o preenchimento incompleto ou impressos de registros médicos, a plataforma pretende implementar contratos inteligentes escritos na linguagem GO, assegurando que as regras de negócio envolvidas nos registros do prontuário eletrônico sejam efetivamente cumpridas [Tribunal de Contas da União (TCU), 2020].

A RNDS complementa a segurança agregada ao sistema pela cadeia de blocos oferecendo serviços como: (i) emissão de **Certificados Digitais**, isto é, documentos eletrônicos contendo dados sobre a pessoa física ou jurídica que o utiliza, servindo como uma identidade virtual que confere validade jurídica e aspectos de segurança digital; (ii) **Serviço de Elegibilidade**, serviço validador dos dados disponibilizados que define se o profissional de saúde está habilitado ou não a acessar os dados do cidadão, aplicando regras de vinculação do profissional com o estabelecimento de saúde, CPF, categoria profissional, certificação da instalação de prontuário eletrônico; (iii) **Consentimento**, relacionado ao modelo de consentimento *opt-out*. Por padrão, assume-se a existência de um consentimento implícito, até que o cidadão opte pela revogação explícita do consentimento [Santos et al., 2022].

Avaliações preliminares utilizando a prova de conceito arquitetural estimam que a RNDS poderá suportar até 1.800 transações por segundo (tps), taxa satisfatória para suportar a quantidade anual de atendimentos prevista no SUS [Tribunal de Contas da União (TCU), 2020]. Atualmente, o Ministério de Saúde disponibiliza três portais³⁶ de acesso às informações armazenadas na RNDS, o ConecteSUS Cidadão, ConecteSUS Profissional e ConecteSUS Gestão, direcionados aos pacientes, aos profissionais de saúde e aos gestores, respectivamente. Ao acessar o portal, cidadãos obtêm o histórico vacinal e outros registros pessoais de saúde, profissionais de saúde visualizam toda a trajetória clínica e

³⁶Disponível em <https://conectesus.saude.gov.br/home>.

de procedimentos dos seus pacientes e gestores conseguem acompanhar a evolução dos indicadores de saúde, fundamentais para coordenação de políticas públicas. A Tabela 4.3 sintetiza as principais características apresentadas por soluções de saúde baseadas em cadeias de blocos.

Tabela 4.3. Características relacionadas às soluções de saúde baseadas em cadeias de blocos.

Tipo	Características	MediBChain [Al Omar et al., 2017]	MedicalChain [Albeyatt, 2018]	MedChain [Sandgaard e Wishstar, 2018]	Patel et al. [Patel, 2019]	Ghorbel et al. [Ghorbel et al., 2021]	AuditChain [Anderson, 2018]	FHIRChain [Zhang et al., 2018]	MedRec [Azaria et al., 2016]	Medblock [Fan et al., 2018]	Ancile [Dagher et al., 2018]	RNDS ³⁷
Cadeia de Blocos	Privada										✓	✓
	Permissionada											
	Pública	✓				✓		✓		✓		
	Permissionada											
Cadeia de Blocos	Privada				✓							
	Não Permissionada											
Mecanismo de Consenso	Não Especificado		✓ ¹	✓ ¹			✓ ¹		✓ ¹			
	Prova de Trabalho	✓						✓	✓		✓	
	Prova de Participação				✓							
	Consenso Raft											✓
	Tolerância Prática a Falhas Bizantinas		✓	✓								
	Consenso Híbrido ou Próprio									✓		
Mecanismo de Consenso	Não Especificado					✓ ²	✓ ²					

✓¹: Os autores apenas informam que a cadeia de blocos é permissionada, não a especificando-a como pública ou privada. Contudo, assume-se como uma rede privada.

✓²: Os autores apenas informam que o mecanismo de consenso adotado é flexível.

4.6. Discussão, Tendências e Desafios de Pesquisa

Embora seja potencialmente utilizável, a tecnologia de cadeia de blocos ainda é considerada um tecnologia complementar aos sistemas legados e não os substitui. A Tabela 4.5 resume os principais obstáculos técnicos na incorporação da tecnologia de cadeia de blocos no setor de saúde. A **escalabilidade** apresenta-se como um potencial entrave à adoção convencional de cadeias de blocos nos setores de saúde. Embora não seja impactante em cadeias de blocos privadas, a falta de escalabilidade é claramente uma questão preocupante em cadeias de blocos públicas. Comparada às redes de transações tradicionais, capazes de processar milhares de transações por segundo, as cadeias de blocos públicas limitam-se a dezenas de transações por segundo [Chowdhury et al., 2019, Lo et al., 2017]. Dependendo da plataforma e do mecanismo de consenso implementado, a latência introduzida pelo processo de validação de um bloco pode alcançar até 10 minutos [Chowdhury et al., 2019]. Ademais, a escolha inadequada do mecanismo de

³⁷Disponível em <https://www.gov.br/saude/pt-br/assuntos/rnds>.

Tabela 4.4. Vantagens e desvantagens apresentadas por diferentes soluções acadêmicas de EMR baseadas em cadeias de blocos.

	Diferencial	Vantagens	Desvantagens
[Dubovitskaya et al., 2017]	Sistema EMR baseado em cadeia de blocos permissionada	Privacidade dos dados de usuário	Controle de acesso limitado aos dados de pacientes
[Azaria et al., 2016]	Sistema EMR baseado em cadeia de blocos pública	Controle de acesso baseado em contratos inteligentes	Alto processamento computacional
[Guo et al., 2018]	Sistema EMR distribuído	Assinaturas baseadas em atributos para gerenciamento de PHR	Custos de sinalização e problemas de confiabilidade
[Dang et al., 2018]	Sistema EMR baseado em nuvem e névoa	Assinaturas baseadas em atributos para confidencialidade e privacidade	Custos de sinalização e ambiente limitado
[Yue et al., 2016]	Sistema EMR baseado em <i>gateway</i>	Controle de privacidade grosseiro	Controle limitado de transações
[Makary e Daniel, 2016]	Mercado de dados de saúde	Controle de privacidade centrado no paciente	Gerenciamento complexo do MedToken
[Al Omar et al., 2017]	EMR centrado no paciente	Pseudoanonimato de chaves públicas	Gerenciamento complexo de chaves
[Anderson, 2018]	Controle de acesso em multinível	Token virtual para assinatura digital de transação	<i>Scripts</i> de solicitação complexos
[Uddin et al., 2018]	Agente centrado no paciente	Controle de acesso baseado em papéis	Alto custo de processamento
[Zhang e Poslad, 2018]	Controle de acesso em camadas	Controle de permissão refinado	Longos atrasos de validação e recuperação
[Xia et al., 2017]	Sistema com controle e gerenciamento de dados baseado em cadeia de blocos	Controle de acesso complexo	Chave de acesso e escalabilidade
[Liang et al., 2017]	Sistema móvel de compartilhamento de registro médico baseado em cadeia de blocos	Compartilhamento de dados colaborativo e uso de árvore com raiz de Merkle para segurança	Interoperabilidade
[Jiang et al., 2018]	Sistema para intercâmbio de dados baseado em cadeia de blocos	Integra abordagens fora da cadeia e a verificação na cadeia para garantia de privacidade e autenticidade	Complexidade do sistema de acesso e desempenho
[Fan et al., 2018]	Sistema de compartilhamento eficiente e seguro baseado em cadeia de blocos	Gerenciamento e compartilhamento de registros de sistemas de EMR e mecanismo de acesso	Suscetibilidade a falhas devido ao alto custo de processamento

consenso impacta no aumento do tempo de criação de blocos. Paralelamente, à medida que o número de transações e nós na rede aumenta, mais verificações devem ser realizadas e, conseqüentemente, maior a probabilidade de formação de gargalos. Sob a ótica de sistemas de saúde, esses potenciais atrasos afetam adversamente a análise de exames e a definição rápida de diagnósticos [De Aguiar et al., 2020]. Contudo, há uma pluralidade de abordagens capazes de resolver essa questão. Uma das abordagens é a utilização de *sharding*, uma técnica baseada na divisão da rede em diferentes fragmentos (*shards*), de modo que a duplicação compulsória da comunicação, do armazenamento de dados e da sobrecarga de computação seja evitada para cada nó participante. Essa abordagem desobriga que cada nó lide com toda carga transacional da rede, permitindo que apenas mantenham os dados sobre seu fragmento [Yu et al., 2020]. Outra abordagem consiste em modificar a tradicional estrutura linear das cadeias de bloco para uma representação na forma de Grafo Acíclico Direcionado (*Directed Acyclic Graph* – DAG). Nessa nova estruturação, cada transação é vinculada a múltiplas transações, permitindo o paralelismo do processo de validação [Kaur e Gandhi, 2020].

Os sistemas de saúde baseados em cadeias de blocos são desenvolvidos agrupando conceitos multidisciplinares que englobam tanto conhecimentos de tecnologia da informação quanto competências e fluxos de atendimento da área médica. Contudo, a baixa presença de profissionais qualificados e a alta complexidade de manipulação e manutenção contribuem para tais sistemas serem frequentemente vinculados à fraca **usabilidade** [De Aguiar et al., 2020]. Em 2019, o Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br) apontou que apenas 20% dos estabelecimentos de saúde, sejam eles privados ou públicos, detinham um profissional com formação na área da saúde alocado em seus respectivos departamentos de TI. Essa escassez de profissionais de saúde atuantes na área técnica é igualmente acompanhada na porcentagem de presença de equipes de TI internas em estabelecimentos de saúde. No cenário brasileiro, por exemplo, 21% dos estabelecimentos de saúde têm uma equipe interna destinada ao suporte técnico na área de TI, enquanto 39% deles tinham um prestador de serviço contratado pelo próprio estabelecimentos [Cetic.br, 2020]. As dificuldades são reduzidas ao priorizar a criação de interfaces intuitivas e habilitadas para os usuário.

Intrínseca às cadeias de bloco, a característica de imutabilidade estabelece que após registrados nos blocos, os dados armazenados não são passíveis de alteração. Como cada nó da rede detém uma réplica da cadeia, qualquer tentativa de modificação dos dados em uma dessas réplicas é traduzida pelos nós participantes como um ataque iminente. Como consequência, essas tentativas de alteração são rejeitadas, impossibilitando o apagamento ou edição dos dados, que não pode ser feito nem mesmo pelos próprio autores ou por ordem judicial [Mattos et al., 2018]. Essa característica impõe aos sistemas baseados em cadeia de blocos a necessidade de lidar com a **irreversibilidade** dos registros realizados na cadeia. Embora a autenticidade seja inviolável numa cadeia de blocos, não há garantias sobre a precisão dos dados armazenados. Assim, blocos contendo informações falsas ou incorretas, mesmo que intencionalmente inseridas, não podem ser removidos ou modificados. A inflexibilidade na manipulação dos dados contrasta-se com necessidades de armazenamento presentes em sistemas de EMR. Por não apresentarem atributos críticos ou valiosos para diagnósticos futuros, alguns dados são armazenados temporariamente. Outros dados como endereço ou características pessoais dos pacientes, embora não sejam críticos, requerem atualizações constantes. Ambas as situações destacam que o armazenamento indiscriminado de dados na cadeia de blocos é um fator limitante para a adoção da tecnologia, dada a impossibilidade de exclusão de registros antigos. Outro fator desafiador é a exposição de chaves privadas. Caso ocorra, os dados dos pacientes estarão expostos para quaisquer indivíduos ou entidades detentores da chave privada, não havendo a possibilidade de utilizar uma nova chave para criptografar novamente os dados já registrados na cadeia. Portanto, qualquer vazamento de chave expõe permanentemente a privacidade do paciente caso seus dados sejam gravados na cadeia [Lo et al., 2017].

Outro aspecto sensível remete à **privacidade e segurança** dos dados, visto que todos os nós acessam os dados transmitidos por outro nó. Ao acessar suas próprias informações ou histórico médico, os pacientes são dependentes de uma entidade intermediadora, caso ocorra uma emergência. Esse fator rompe os princípios de privacidade estabelecidos nas legislações vigentes de proteção de dados. A expansão do poder computacional dos sistemas modernos representa sérias ameaças à segurança da cadeia de blocos, sobretudo quando se baseiam em criptografia de chave pública. Tal vulnerabilidade relaciona-se

à suposição de que os computadores clássicos são incapazes de fatorar grandes números rapidamente. Contudo, essa hipótese é refutada perante o surgimento da computação quântica, uma tecnologia emergente que pretende resolver desafios criptográficos altamente complexos de maneira rápida e eficiente. Dentre as alternativas para enfrentamento desse desafio, ressalta-se a substituição das assinaturas digitais convencionais por criptografia resistente a *quantum* [Yaqoob et al., 2022]. Paralelamente, redes baseadas em PoW também são propensas a violar a segurança criptográfica. Essa violação ocorre através do Ataque de 51%, uma ação maliciosa em que um grupo de mineradores detém a fração majoritária do poder computacional da rede de cadeia de blocos e, portanto, esses nós ditam o processo de adição de blocos à rede [Mattos et al., 2018]. Logo, um sistema de saúde prejudicado por esse ataque pode significar a perda de credibilidade das organizações.

Para usufruir do potencial da tecnologia de cadeias de blocos em cuidados de saúde, é essencial abordar os desafios relacionados à **interoperabilidade**. Essa propriedade remete à capacidade de trocar informações entre sistemas com características heterogêneas. Para tornar dois sistemas de EMR interoperáveis, as mensagens de transmissão devem ser baseadas em dados codificados padronizados. Embora a ausência de padrões de cadeias de blocos simplifique a função dos desenvolvedores, essa indefinição contribui para problemas de comunicação entre sistemas distintos. Assim, a falta de interoperabilidade entre sistemas é potencializada pela existência de várias redes de cadeias de blocos baseadas em diferentes mecanismos de consenso, mecanismos de transação e funcionalidades de contratos inteligentes. No âmbito de saúde, a adoção de tecnologias clínicas, especificações técnicas e capacidades funcionais tradicionalmente díspares, também trava a criação e compartilhamento de dados em um formato único. Constata-se que, mesmo desenvolvidos sobre a mesma plataforma, diversos sistemas de EMR não são interoperáveis dado que foram projetados para atender necessidades e preferências específicas de uma instituição de saúde. Na prática, a falta de dados padronizados limita a capacidade de compartilhar os dados eletronicamente para o atendimento ao paciente. Uma solução plausível para esse problema é o desenvolvimento de novos padrões, que possam ser aderidos por soluções legadas. Com esse propósito, a *Enterprise Ethereum Alliance*³⁸ (EEA) introduziu uma versão padronizada da cadeia de blocos Ethereum [Yaqoob et al., 2022, Mattos et al., 2018].

Além dos desafios técnicos relacionados à adoção da cadeia de blocos, também existem diversos desafios relacionados aos sistemas de saúde. Destacam-se desafios de interoperabilidade entre sistemas, padronização e integração dos dados, segurança dos dados e privacidade. A **interoperabilidade entre os sistemas** é particularmente importante para permitir o acesso rápido e fácil a informações precisas e atualizadas sobre os pacientes para tomar decisões clínicas bem informadas. Contudo, tanto o gerenciamento de dados de saúde quanto a interoperabilidade entre os sistemas são desafios devido à heterogeneidade de informações e sistemas. Os diversos sistemas devem ser desenvolvidos levando em consideração as boas práticas da segurança da informação. Os dados de saúde devem ser padronizados para permitir a consistência e a interoperabilidade entre sistemas distintos. Os padrões também regem a captura, armazenamento e recuperação da informação. Dessa forma, os sistemas desenvolvidos devem estar em conformidade com os

³⁸Disponível em <https://entethalliance.org/>.

Tabela 4.5. Desafios enfrentados no emprego da tecnologia de cadeia de blocos em sistemas de saúde.

Obstáculo Técnico	Desafios
Escalabilidade	Tamanho do bloco e tempo de criação do bloco
	Adoção de mecanismos de consenso ineficientes
	Tempos de confirmação mais altos para a criação de um bloco
	Aumento exponencial do número de verificações conforme cresce o número de transações e nós na rede
Usabilidade	Complexidade no desenvolvimento e manutenção de sistemas de saúde baseados em cadeia de blocos
	Carência de profissionais familiarizados com a gestão de redes par-a-par complexas
Irreversibilidade	Imutabilidade das informações armazenadas nos blocos
Privacidade e Segurança	Emprego de assinaturas digitais convencionais é vulnerável à computação quântica
	Porcentagem majoritária do poder computacional da rede ser controlado por uma única entidade
Interoperabilidade	Utilização de diferentes mecanismos de consenso, mecanismos de transação e funcionalidades de contratos inteligentes

padrões adotados internacionalmente e devem existir *backups* regulares e políticas claras de retenção de dados para evitar perdas. A conformidade com os padrões também garante a qualidade dos dados capturados. Adicionalmente, deve ser possível realizar auditorias regulares sobre os dados para melhorar a confiabilidade das informações. O uso de sistemas de integração de dados também pode ajudar a conectar diferentes sistemas e bases de dados de saúde, permitindo que os dados sejam compartilhados de maneira segura e eficiente. As APIs, por sua vez, podem ajudar a padronizar a maneira como diferentes sistemas e bases de dados se comunicam e interagem, permitindo o compartilhamento de informações e dados de forma mais fácil e segura. Alguns projetos de pesquisa e ações governamentais em andamento na área de integração de sistemas de saúde são:

- IHE (*Integrating the Healthcare Enterprise*)³⁹ é uma iniciativa global que desenvolve e promove padrões para interoperabilidade de sistemas de saúde, com o objetivo de melhorar a qualidade e a eficiência da assistência à saúde;
- *Common Platform*⁴⁰ é um projeto de pesquisa financiado pela União Europeia que visa desenvolver uma plataforma comum para compartilhamento de informações de saúde entre diferentes países europeus. O projeto utiliza padrões de comunicação e segurança para garantir que os dados de saúde sejam compartilhados de maneira segura e eficiente;
- iDASH (*Integrating Data for Analysis, Anonymization, and Sharing*) [Ohno-Machado et al., 2011] é um projeto de pesquisa financiado pelo governo dos Estados Unidos que visa desenvolver uma plataforma para compartilhamento de dados de saúde entre diferentes organizações de saúde. O projeto emprega técnicas de anonimização e segurança para garantir que os dados de saúde sejam compartilhados de maneira segura e protegida;

³⁹Disponível em <https://www.ihe.net/>.

⁴⁰Disponível em <https://cordis.europa.eu/project/id/225005>.

- RNDS é uma iniciativa governamental brasileira que desenvolve uma plataforma nacional de interoperabilidade para troca de dados em saúde. O objetivo principal é facilitar o acesso e a troca de dados entre os diferentes sistemas de informação em saúde no Brasil, públicos e privados. A plataforma possibilita a troca segura de dados de saúde de forma padronizada e em conformidade com as políticas de privacidade e segurança vigentes.

Os sistemas tradicionais de saúde também apresentam desafios em relação à **segurança de dados**. É fundamental garantir a segurança dos dados de saúde, incluindo o acesso seguro e o controle da privacidade do paciente. Isso inclui a implementação de políticas de segurança da informação, criptografia de dados sensíveis, autenticação de usuários e monitoramento contínuo de atividades suspeitas. O uso de ferramentas disponíveis no cotidiano médico fomenta a discussão sobre as práticas de gerenciamento de dados e segurança na área de saúde, ressaltando a necessidade de *software* de fácil manipulação, baixo custo, boa usabilidade, com boas práticas de segurança e agilidade [Araujo Gomes de Castro et al., 2020]. O ambiente médico tem características próprias, complexas e mutáveis com rotinas e procedimentos complexos e com atualizações constantes. A demanda de manipulação dos dados por equipes médica, que podem estar distante geograficamente, inclui o aumento de fluxos de dados que precisam de segurança e demandam criptografia. Além disso, a evolução das tecnologias voltadas para a saúde resulta no aumento da quantidade de dados de saúde digitais disponíveis [Blandford et al., 2020] e, conseqüentemente, pode haver maior interesse de agentes maliciosos em acessar tais dados. A gestão dos dados deve ser bem estabelecida para assegurar a conformidade com os requisitos regulamentares e as normas vigentes. É fundamental definir papéis e responsabilidades para garantir que apenas quem precisa ter acesso aos dados os acessem de forma segura. Outro desafio é que sistemas de saúde digital agregam complexidade ao ambiente hospitalar, culminando na necessidade de treinamento de equipes multidisciplinares para garantir o acesso seguro e contínuo aos dados sensíveis.

A pandemia da COVID-19 acelerou o processo, incentivando o rápido aumento do uso de tecnologias no cuidado com a saúde. Surtos de doenças anteriores já alertavam para o perigo da sobrecarga de unidades de saúde. A Organização Mundial de Saúde (OMS) atualizou as diretrizes de planejamento operacional durante a pandemia, equilibrando as exigências de responder diretamente à COVID-19, e manter o funcionamento e continuidade de serviços de saúde já existentes, mantendo ainda o padrão de saúde e sanitário, importante no decorrer das ações para mitigar problemas endêmicos e futuros. Nesse cenário, a necessidade de programas que estabelecem a comunicação, assistência e atendimento com qualidade cresceu e a urgência necessária no desenvolvimento trouxe muitos problemas como soluções em *software* que não se comunicam durante o atendimento médico. Os atendimentos via Internet foram feitos realizados, porém em um ambiente desafiador por precisar de vários sistemas que aumentam a complexidade do atendimento médico. Nesse ambiente, a interoperabilidade se torna essencial para o atendimento eficiente do paciente. Há trabalhos e relatos experimentais de como a telessaúde está evoluindo rapidamente, originando inúmeros desafios novos e fomentando desafios antigos. A interoperabilidade, a transparência, a segurança, a rapidez e a disponibilidade são essenciais nos próximos avanços e desenvolvimentos na telessaúde. Assim, as pesquisas em saúde estão fortemente direcionadas para a telessaúde e sistemas inovadores.

A telessaúde constitui uma área estratégica por seu potencial intrínseco de ser fonte geradora de inovações, por demandar e incorporar avanços tecnológicos oriundos de outras áreas, em função da sua natureza interdisciplinar e de suas inter-relações dinâmicas, e pela possibilidade de impulsionar diferentes áreas⁴¹. Além disso, ressalta-se o aumento da prevalência de doenças crônicas, como insuficiência cardíaca, doença pulmonar e diabetes, que podem ser acompanhadas por meio da telessaúde. Assim, a telessaúde pode melhorar o acesso aos serviços de saúde, reduzir os custos, melhorar os resultados dos pacientes e reduzir a propagação de doenças infecciosas, reduzindo o número de visitas presenciais a instalações de cuidados de saúde. A União Europeia tem feito esforços para implementação e padronização da telessaúde⁴². A interoperabilidade permite que os prestadores de cuidados de saúde partilhem informações sobre os pacientes de forma segura e eficiente, reduzindo o risco de erros e melhorando os resultados dos pacientes. Dentre as novas tecnologias estão a robotização e automatização de laboratórios centrais, multiplicando ao mesmo tempo novos dispositivos para uso periférico e pessoal, com interoperabilidade. Os padrões garantem a interoperabilidade entre componentes heterogêneos e permitem o desenvolvimento de sistemas baseados na descentralização. No Brasil, o Ministério da Saúde, com a Portaria no 2.073 de 2011, define os padrões de interoperabilidade para sistemas de saúde.

Outro desafio relaciona-se à **privacidade** dos dados de saúde. O paradigma da Internet das Coisas, que dissemina e populariza o uso de objetos do cotidiano como câmeras e dispositivos móveis e vestíveis capazes de se comunicarem, permite o monitoramento da saúde dos pacientes. Na China, por exemplo, um sistema que determinava remotamente quem deveria fazer quarentena durante a pandemia de COVID-19 usou dados obtidos por meio de câmeras térmicas em locais públicos com tecnologia de reconhecimento facial e um aplicativo que verificava funções vitais dos usuários diariamente. Vários países europeus usaram redes móveis para informar e identificar pessoas em risco de contaminação [Chén e Roberts, 2021]. Essas aplicações trazem à tona preocupações relacionadas à privacidade dos usuários e à gerência dos dados desses usuários. Especula-se que o uso de dispositivos portáteis e vestíveis continuará a crescer, sendo esses dispositivos cada vez mais usados nos cuidados digitais da saúde [Chén e Roberts, 2021]. Assim, é fundamental buscar soluções que protejam a privacidade dos usuários.

4.7. Considerações Finais

A rápida evolução das ferramentas de Tecnologia da Informação e Comunicação (TIC) no setor de saúde destaca o papel cada vez mais vital dos sistemas eletrônicos e plataformas digitais. A capacidade de compartilhar informações do paciente com eficiência e precisão entre diferentes sistemas médicos tem o potencial de revolucionar a prestação de cuidados de saúde, aprimorar o atendimento ao paciente e impulsionar pesquisas inovadoras. No entanto, o desafio reside na complexidade inerente e na diversidade dos formatos de dados usados em vários sistemas médicos, dificultando a interoperabilidade

⁴¹Disponível em <https://www.who.int/fr/news/item/30-03-2020-who-release-s-guidelines-to-help-countries-maintain-essential-health-services-during-the-covid-19-pandemic>

⁴²Disponível em <https://dialnet.unirioja.es/servlet/articulo?codigo=5635387>

crucial para atingir esses objetivos transformadores. Como resultado, a complexidade do sistema médico impede o acesso fácil ao histórico médico completo do paciente, quando necessário, levando à perda ou coleta repetitiva de informações, dificultando o diagnóstico e o tratamento e impactando negativamente a jornada do paciente.

Os ambientes eletrônicos de saúde facilitam o acesso a dados distribuídos, armazenando os dados do paciente em Registros Médicos Eletrônicos (EMRs) padronizados. Os EMRs contêm informações pessoais privadas sobre o paciente, incluindo diagnósticos e tratamentos, e são normalmente distribuídos entre hospitais e clínicas que trataram o paciente pelo menos uma vez na vida. Os EMRs permitem acesso rápido e padronizado aos dados do paciente e permitem a integração do atendimento ao paciente entre equipes médicas e diferentes unidades de saúde, garantindo que diferentes níveis de atendimento tenham acesso às informações médicas relevantes de cada paciente. Os EMRs são altamente sensíveis e confidenciais. Contudo, o compartilhamento ocorre, por vezes, sem o consentimento do paciente entre entidades não confiáveis, como profissionais de saúde, farmácias, familiares e outros médicos. Embora sistemas institucionalizados seguros sejam usados para compartilhar dados do paciente quando necessário, dados sensíveis também são compartilhados usando meios de comunicação informais e inseguros.

No contexto da pandemia de COVID-19, a necessidade de agilizar o atendimento e o fluxo de informações entre pacientes, médicos e instituições de saúde tornou-se ainda mais crucial. Os registros de pacientes ganham importância crescente em termos de saúde pública e dados sobre diagnósticos e medicamentos prescritos podem ser usados para identificar indivíduos em risco de doenças como a COVID-19. A maior disponibilidade de dados do paciente em formato eletrônico é de grande relevância para a tomada de decisões e continuidade do cuidado tanto no setor público quanto no privado, principalmente com troca de informações entre as duas esferas. A detecção precoce de surtos de doenças é crucial para coordenar as políticas de saúde pública e os esforços de prevenção em nível nacional de forma eficiente. O compartilhamento eficiente também beneficia os pacientes, pois permite que eles acessem suas próprias informações a qualquer momento, como resultados laboratoriais e de imagem, e facilita a portabilidade desses dados para outros profissionais de saúde. A comunicação eficiente e automatizada entre pacientes e equipes médicas promove a transparência, aumenta a satisfação do paciente e garante o acesso universal aos dados. No entanto, ainda há desafios a serem enfrentados. A maioria dos sistemas de EMR é baseada em arquiteturas cliente-servidor centralizadas, que apresentam desafios de privacidade e segurança. As vulnerabilidades do sistema podem levar a falhas e criar oportunidades para que invasores cibernéticos comprometam os dados do paciente. Além disso, os registros dos pacientes geralmente são fragmentados em bancos de dados locais, impedindo a consolidação do histórico médico eletrônico do paciente. A padronização dos formatos de dados é essencial para alcançar a interoperabilidade no setor de saúde. A padronização envolve o estabelecimento de uma linguagem comum para troca e interpretação de dados médicos, permitindo que diferentes sistemas se comuniquem entre si.

A tecnologia de cadeia de blocos é uma candidata à interface de padronização e interoperação entre sistemas de saúde. Embora tenha potencial para ser usada no setor de saúde, ela ainda é considerada uma tecnologia complementar aos sistemas legados, e não uma substituta. A integração da tecnologia de cadeia de blocos na área da saúde apresenta

vários desafios técnicos, incluindo escalabilidade, usabilidade, irreversibilidade, privacidade e segurança e interoperabilidade. A escalabilidade é um obstáculo potencial para a adoção generalizada de cadeias de blocos públicos no setor de saúde. As cadeias de blocos públicas têm limitações em termos de velocidade de processamento de transações e tempo de validação de blocos, o que pode afetar adversamente a análise de exames médicos e o diagnóstico oportuno. A usabilidade é outro desafio nos sistemas de saúde baseados em cadeia de blocos. A complexidade de gerenciamento e manutenção desses sistemas, juntamente com a escassez de profissionais qualificados com experiência em saúde e TIC, muitas vezes resulta em sistemas com baixa usabilidade. A característica de imutabilidade na cadeia de blocos promove desafios em termos de manipulação de dados. Depois que os dados são gravados em um bloco, eles não podem ser modificados ou excluídos, o que pode ser problemático para armazenar dados temporários ou não críticos. Além disso, a exposição de chaves privadas pode comprometer permanentemente a privacidade do paciente. Privacidade e segurança são preocupações críticas em sistemas de saúde baseados em cadeias de blocos. A transparência das redes de cadeias de blocos e a dependência de intermediários para acessar informações pessoais de saúde podem comprometer a privacidade do paciente. Por fim, a interoperabilidade é essencial para a troca de informações entre sistemas heterogêneos na área da saúde. A falta de padronização e a presença de várias redes cadeias de blocos com diferentes mecanismos de consenso, mecanismos de transação e funcionalidades de contratos inteligentes dificultam a interoperabilidade.

Diversos atores no mercado de saúde digital identificam a falta de interoperabilidade entre os sistemas de informações de saúde, o que compromete a segurança dos dados. Esse fato também restringe o acesso às informações, reduzindo a integração entre registros dispersos por clínicas e hospitais. Esse capítulo apresentou as possibilidades de integração e padrões de representação de dados em saúde. Espera-se que nos próximos anos, projetos de pesquisa e produtos comerciais foquem a missão vital de padronização e integração em sistemas de compartilhamento de registros médicos eletrônicos, pois são desafios que detêm a oportunidade de revolucionar a saúde, ampliar os resultados positivos aos pacientes e moldar um futuro em que a colaboração e a inovação prosperem.

Referências

- [Abomhara e Ben Lazrag, 2016] Abomhara, M. e Ben Lazrag, M. (2016). UML/OCL-based modeling of work-based access control policies for collaborative healthcare systems. Em *2016 IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom)*, p. 1–6.
- [Abomhara et al., 2016] Abomhara, M., Yang, H. e Kjøien, G. M. (2016). Access control model for cooperative healthcare environments: Modeling and verification. Em *2016 IEEE International Conference on Healthcare Informatics (ICHI)*, p. 46–54. IEEE.
- [Agrawal et al., 2022] Agrawal, D., Minocha, S., Namasudra, S. e Gandomi, A. H. (2022). A robust drug recall supply chain management system using hyperledger blockchain ecosystem. *Computers in biology and medicine*, 140:105100.
- [Al Omar et al., 2017] Al Omar, A., Rahman, M. S., Basu, A. e Kiyomoto, S. (2017). MediBChain: A blockchain based privacy preserving platform for healthcare data.

- Em *Security, Privacy, and Anonymity in Computation, Communication, and Storage: SpaCCS 2017 International Workshops, Guangzhou, China, December 12-15, 2017, Proceedings 10*, p. 534–543. Springer.
- [Albeyatt, 2018] Albeyatt, A. (2018). Medicalchain white paper 2.1. Relatório técnico, MedChain White Paper 2.1.
- [Anderson, 2018] Anderson, J. (2018). Securing, standardizing, and simplifying electronic health record audit logs through permissioned blockchain technology. *UNTHRR*.
- [Araujo Gomes de Castro et al., 2020] Araujo Gomes de Castro, F., Oliveira dos Santos, Á., Valadares Labanca Reis, G., Brandão Viveiros, L., Hespanhol Torres, M. e de Oliveira Junior, P. P. (2020). Telemedicina rural e COVID-19: ampliando o acesso onde a distância já era regra. *Revista Brasileira de Medicina de Família e Comunidade*, 15(42):2484.
- [Azaria et al., 2016] Azaria, A., Ekblaw, A., Vieira, T. e Lippman, A. (2016). MedRec: Using blockchain for medical data access and permission management. Em *2016 2nd international conference on open and big data (OBD)*, p. 25–30. IEEE.
- [Blandford et al., 2020] Blandford, A., Wesson, J., Amalberti, R., AlHazme, R. e Allwihan, R. (2020). Opportunities and challenges for telehealth within, and beyond, a pandemic. *The Lancet Global Health*, 8(11):e1364–e1365.
- [Byun et al., 2005] Byun, J.-W., Bertino, E. e Li, N. (2005). Purpose based access control of complex data for privacy protection. Em *Proceedings of the Tenth ACM Symposium on Access Control Models and Technologies, SACMAT '05*, p. 102–110, New York, NY, USA. Association for Computing Machinery.
- [Cachin e Vukolic, 2017] Cachin, C. e Vukolic, M. (2017). Blockchain Consensus Protocols in the Wild (Keynote Talk). Em Richa, A. W., editor, *31st International Symposium on Distributed Computing (DISC 2017)*, volume 91 of *Leibniz International Proceedings in Informatics (LIPIcs)*, p. 1:1–1:16, Dagstuhl, Germany. Schloss Dagstuhl–Leibniz-Zentrum fuer Informatik.
- [Carrara et al., 2020] Carrara, G. R., Burle, L. M., Medeiros, D. S. V., de Albuquerque, C. V. N. e Mattos, D. M. F. (2020). Consistency, availability, and partition tolerance in blockchain: a survey on the consensus mechanism over peer-to-peer networking. *Annals of Telecommunications*, 75(3):163–174.
- [Cetic.br, 2020] Cetic.br (2020). *Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros : TIC Saúde 2019*. Núcleo de Informação e Coordenação do Ponto BR (NIC.br).
- [Chowdhury et al., 2019] Chowdhury, M. J. M., Ferdous, M. S., Biswas, K., Chowdhury, N., Kayes, A., Alazab, M. e Watters, P. (2019). A comparative analysis of distributed ledger technology platforms. *IEEE Access*, 7:167930–167943.
- [Christidis e Devetsikiotis, 2016] Christidis, K. e Devetsikiotis, M. (2016). Blockchains and smart contracts for the internet of things. *IEEE Access*, 4:2292–2303.

- [Chén e Roberts, 2021] Chén, O. Y. e Roberts, B. (2021). Personalized health care and public health in the digital age. *Frontiers in Digital Health*, 3.
- [Dagher et al., 2018] Dagher, G. G., Mohler, J., Milojkovic, M. e Marella, P. B. (2018). Ancile: Privacy-preserving framework for access control and interoperability of electronic health records using blockchain technology. *Sustainable cities and society*, 39:283–297.
- [Dang et al., 2018] Dang, L., Dong, M., Ota, K., Wu, J., Li, J. e Li, G. (2018). Resource-efficient secure data sharing for information centric e-health system using fog computing. Em *2018 IEEE International Conference on Communications (ICC)*, p. 1–6. IEEE.
- [Daraghmi et al., 2019] Daraghmi, E.-Y., Daraghmi, Y.-A. e Yuan, S.-M. (2019). Med-Chain: a design of blockchain-based system for medical records access and permissions management. *IEEE Access*, 7:164595–164613.
- [De Aguiar et al., 2020] De Aguiar, E. J., Faiçal, B. S., Krishnamachari, B. e Ueyama, J. (2020). A survey of blockchain-based strategies for healthcare. *ACM Comput. Surv.*, 53(2).
- [de Oliveira et al., 2019] de Oliveira, M. T., Reis, L. H., Carrano, R. C., Seixas, F. L., Saade, D. C., Albuquerque, C. V., Fernandes, N. C., Olabbarriaga, S. D., Medeiros, D. S. e Mattos, D. M. (2019). Towards a blockchain-based secure electronic medical record for healthcare applications. Em *ICC 2019-2019 IEEE International Conference on Communications (ICC)*, p. 1–6. IEEE.
- [de Oliveira et al., 2023] de Oliveira, M. T., Verginadis, Y., Reis, L. H., Psarra, E., Patiniotakis, I. e Olabbarriaga, S. D. (2023). AC-ABAC: Attribute-based access control for electronic medical records during acute care. *Expert Systems with Applications*, 213:119271.
- [DICOM, 2023] DICOM, D. S. C. (2023). Dicom ps3.1 2023b. Relatório técnico, DICOM Standards Committee.
- [Dubovitskaya et al., 2017] Dubovitskaya, A., Xu, Z., Ryu, S., Schumacher, M. e Wang, F. (2017). Secure and trustable electronic medical records sharing using blockchain. Em *AMIA annual symposium proceedings*, volume 2017, p. 650. American Medical Informatics Association.
- [Engelhardt, 2017] Engelhardt, M. A. (2017). Hitching healthcare to the chain: An introduction to blockchain technology in the healthcare sector. *Technology Innovation Management Review*, 7(10).
- [Fan et al., 2018] Fan, K., Wang, S., Ren, Y., Li, H. e Yang, Y. (2018). MedBlock: Efficient and secure medical data sharing via blockchain. *Journal of medical systems*, 42:1–11.
- [Ghorbel et al., 2021] Ghorbel, A., Ghorbel, M. e Jmaiel, M. (2021). Accountable privacy preserving attribute-based access control for cloud services enforced using block-

- chain. *International Journal of Information Security*, p. 1–20.
- [Guo et al., 2018] Guo, R., Shi, H., Zhao, Q. e Zheng, D. (2018). Secure attribute-based signature scheme with multiple authorities for blockchain in electronic health records systems. *IEEE access*, 6:11676–11686.
- [Haas et al., 2011] Haas, S., Wohlgemuth, S., Echizen, I., Sonehara, N. e Müller, G. (2011). Aspects of privacy for electronic health records. *International Journal of Medical Informatics*, 80(2):e26–e31. Special Issue: Security in Health Information Systems.
- [Harrison et al., 2021] Harrison, J. E., Weber, S., Jakob, R. e Chute, C. G. (2021). ICD-11: an international classification of diseases for the twenty-first century. *BMC Medical Informatics and Decision Making*, 21(6).
- [HL7, 2015] HL7, H. L. S. I. (2015). H17 implementation guide for cda® release 2: Consolidated cda templates for clinical notes (us realm) draft standard for trial use release 2.1. Relatório técnico, Health Level Seven International.
- [Hurst et al., 2022] Hurst, W., Tekinerdogan, B., Alskaf, T., Boddy, A. e Shone, N. (2022). Securing electronic health records against insider-threats: A supervised machine learning approach. *Smart Health*, 26:100354.
- [Jacquemard et al., 2020] Jacquemard, T., Doherty, C. P. e Fitzsimons, M. B. (2020). Examination and diagnosis of electronic patient records and their associated ethics: a scoping literature review. *BMC Medical Ethics*, 21(1):76.
- [Janett e Yeracaris, 2020] Janett, R. S. e Yeracaris, P. P. (2020). Electronic medical records in the american health system: challenges and lessons learned. *Ciencia & saude coletiva*, 25:1293–1304.
- [Jiang et al., 2018] Jiang, S., Cao, J., Wu, H., Yang, Y., Ma, M. e He, J. (2018). Blochie: a blockchain-based platform for healthcare information exchange. Em *2018 ieee international conference on smart computing (smartcomp)*, p. 49–56. IEEE.
- [Kaur e Gandhi, 2020] Kaur, G. e Gandhi, C. (2020). Scalability in blockchain: Challenges and solutions. Em *Handbook of Research on Blockchain Technology*, p. 373–406. Elsevier.
- [Larrucea et al., 2020] Larrucea, X., Moffie, M., Asaf, S. e Santamaria, I. (2020). Towards a GDPR compliant way to secure european cross border healthcare industry 4.0. *Computer Standards and Interfaces*, 69:103408.
- [Lee et al., 2021] Lee, T.-F., Chang, I.-P. e Kung, T.-S. (2021). Blockchain-based healthcare information preservation using extended chaotic maps for HIPAA privacy/security regulations. *Applied Sciences*, 11(22).
- [Lesk, 2013] Lesk, M. (2013). Electronic medical records: Confidentiality, care, and epidemiology. *IEEE security & privacy*, 11(6):19–24.
- [Liang et al., 2017] Liang, X., Zhao, J., Shetty, S., Liu, J. e Li, D. (2017). Integrating

- blockchain for data sharing and collaboration in mobile healthcare applications. Em *2017 IEEE 28th annual international symposium on personal, indoor, and mobile radio communications (PIMRC)*, p. 1–5. IEEE.
- [Lo et al., 2017] Lo, S. K., Xu, X., Chiam, Y. K. e Lu, Q. (2017). Evaluating suitability of applying blockchain. Em *2017 22nd international conference on engineering of complex computer systems (ICECCS)*, p. 158–161. IEEE.
- [Luh e Yen, 2020] Luh, F. e Yen, Y. (2020). Cybersecurity in science and medicine: Threats and challenges. *Trends in Biotechnology*, 38(8):825–828.
- [Maani et al., 2011] Maani, R., Camorlinga, S. e Arnason, N. (2011). A parallel method to improve medical image transmission. *Journal of Digital Imaging*, 25(1):101–109.
- [Maesa et al., 2019] Maesa, D. D. F., Mori, P. e Ricci, L. (2019). A blockchain based approach for the definition of auditable access control systems. *Computers & Security*, 84:93–119.
- [Makary e Daniel, 2016] Makary, M. A. e Daniel, M. (2016). Medical error—the third leading cause of death in the US. *Bmj*, 353.
- [Massad et al., 2003] Massad, E., Marin, H. d. F. e Azevedo Neto, R. S. d., editors (2003). *O prontuário eletrônico do paciente na assistência, informação e conhecimento médico*. USP, São Paulo.
- [Mattos et al., 2018] Mattos, D. M., Medeiros, D. S., Fernandes, N. C., de Oliveira, M. T., Carrara, G. R., Soares, A. A., Magalhães, L. C. S., Passos, D., Carrano, R. C., Moraes, I. M. et al. (2018). Blockchain para segurança em redes elétricas inteligentes: Aplicações, tendências e desafios. *Sociedade Brasileira de Computação*.
- [Mettler, 2016] Mettler, M. (2016). Blockchain technology in healthcare: The revolution starts here. Em *2016 IEEE 18th international conference on e-health networking, applications and services (Healthcom)*, p. 1–3. IEEE.
- [Nakamoto, 2008] Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized business review*, p. 21260.
- [Namasudra et al., 2022] Namasudra, S., Sharma, P., Crespo, R. G. e Shanmuganathan, V. (2022). Blockchain-based medical certificate generation and verification for IoT-based healthcare systems. *IEEE Consumer Electronics Magazine*.
- [Nazerian et al., 2019] Nazerian, F., Motameni, H. e Nematzadeh, H. (2019). Emergency role-based access control E-RBAC and analysis of model specifications with alloy. *Journal of information security and applications*, 45:131–142.
- [Ohno-Machado et al., 2011] Ohno-Machado, L., Bafna, V., Boxwala, A. A., Chapman, B. E., Chapman, W. W., Chaudhuri, K., Day, M. E., Farcas, C., Heintzman, N. D., Jiang, X., Kim, H., Kim, J., Matheny, M. E., Resnic, F. S., Vinterbo, S. A., e the iDASH team (2011). iDASH: integrating data for analysis, anonymization, and sharing. *Journal of the American Medical Informatics Association*, 19(2):196–201.

- [Patel, 2019] Patel, V. (2019). A framework for secure and decentralized sharing of medical imaging data via blockchain consensus. *Health informatics journal*, 25(4):1398–1411.
- [Peleg et al., 2008] Peleg, M., Beimel, D., Dori, D. e Denekamp, Y. (2008). Situation-based access control: Privacy management via modeling of patient data access scenarios. *Journal of Biomedical Informatics*, 41(6):1028–1040.
- [Pustokhin et al., 2021] Pustokhin, D. A., Pustokhina, I. V. e Shankar, K. (2021). *Challenges and Future Work Directions in Healthcare Data Management Using Blockchain Technology*, p. 253–267. Springer Singapore, Singapore.
- [Rahman et al., 2021] Rahman, A., Hossain, M. S., Alrajeh, N. A. e Alsolami, F. (2021). Adversarial examples—security threats to COVID-19 deep learning systems in medical IoT devices. *IEEE Internet of Things Journal*, 8(12):9603–9610.
- [Rebello et al., 2019] Rebello, G., Camilo, G., Silva, L., Souza, L., Guimarães, L., Alchieri, E., Greve, F. e Duarte, O. (2019). Correntes de blocos: Algoritmos de consenso e implementação na plataforma hyperledger fabric. *Sociedade Brasileira de Computação*.
- [Rouhani et al., 2021] Rouhani, S., Belchior, R., Cruz, R. S. e Deters, R. (2021). Distributed attribute-based access control system using permissioned blockchain. *World Wide Web*, p. 1–28.
- [Salim e Park, 2023] Salim, M. M. e Park, J. H. (2023). Federated learning-based secure electronic health record sharing scheme in medical informatics. *IEEE Journal of Biomedical and Health Informatics*, 27(2):617–624.
- [Sandgaard e Wishstar, 2018] Sandgaard, J. e Wishstar, S. (2018). Medchain white paper 2.1. Relatório técnico, MedChain White Paper 2.1.
- [Santos et al., 2022] Santos, S. d. L. V. d., Zara, A. L. d. S. A., Lucena, F. N. d., Ribeiro-Rotta, R. F., Braga, R. D., Amaral, R. G., Pedrosa, S. M. e Kudo, T. N. (2022). *Rede Nacional de Dados em Saúde: o que precisamos saber?* Cegraf UFG.
- [Savage, 2014] Savage, R. (2014). HI7 version 2.5.1, implementation guide for immunization messaging. Relatório técnico, Centers for Disease Control and Prevention.
- [Seol et al., 2018] Seol, K., Kim, Y.-G., Lee, E., Seo, Y.-D. e Baik, D.-K. (2018). Privacy-preserving attribute-based access control model for XML-based electronic health record system. *IEEE Access*, 6:9114–9128.
- [Siyal et al., 2019] Siyal, A. A., Junejo, A. Z., Zawish, M., Ahmed, K., Khalil, A. e Sour-sou, G. (2019). Applications of blockchain technology in medicine and healthcare: Challenges and future perspectives. *Cryptography*, 3(1):3.
- [Stoeger e Schmidhuber, 2020] Stoeger, K. e Schmidhuber, M. (2020). The use of data from electronic health records in times of a pandemic—a legal and ethical assessment. *Journal of Law and the Biosciences*, 7(1):lsaa041.

- [Tanwar et al., 2020] Tanwar, S., Parekh, K. e Evans, R. (2020). Blockchain-based electronic healthcare record system for healthcare 4.0 applications. *Journal of Information Security and Applications*, 50:102407.
- [Tormo et al., 2013] Tormo, G. D., Mármol, F. G., Girao, J. e Pérez, G. M. (2013). Identity management—in privacy we trust: bridging the trust gap in ehealth environments. *IEEE security & privacy*, 11(6):34–41.
- [Tribunal de Contas da União (TCU), 2020] Tribunal de Contas da União (TCU) (2020). Levantamento de aplicações blockchain: Aplicações blockchain no setor pública do brasil (apêndice 1). Sumário executivo, Tribunal de Contas da União (TCU).
- [Tschorsch e Scheuermann, 2016] Tschorsch, F. e Scheuermann, B. (2016). Bitcoin and beyond: A technical survey on decentralized digital currencies. *IEEE Communications Surveys & Tutorials*, 18(3):2084–2123.
- [Uddin et al., 2018] Uddin, M. A., Stranieri, A., Gondal, I. e Balasubramanian, V. (2018). Continuous patient monitoring with a patient centric agent: A block architecture. *IEEE Access*, 6:32700–32726.
- [WHO, 2022] WHO, G. W. H. O. (2022). International classification of diseases, eleventh revision ICD-11. Relatório técnico, World Health Organization.
- [Xia et al., 2017] Xia, Q., Sifah, E. B., Asamoah, K. O., Gao, J., Du, X. e Guizani, M. (2017). MeDShare: Trust-less medical data sharing among cloud service providers via blockchain. *IEEE Access*, 5:14757–14767.
- [Xu et al., 2017] Xu, X., Weber, I., Staples, M., Zhu, L., Bosch, J., Bass, L., Pautasso, C. e Rimba, P. (2017). A taxonomy of blockchain-based systems for architecture design. Em *2017 IEEE international conference on software architecture (ICSA)*, p. 243–252. IEEE.
- [Yaqoob et al., 2022] Yaqoob, I., Salah, K., Jayaraman, R. e Al-Hammadi, Y. (2022). Blockchain for healthcare data management: Opportunities, challenges, and future recommendations. *Neural Computing and Applications*, 34.
- [Yu et al., 2020] Yu, G., Wang, X., Yu, K., Ni, W., Zhang, J. A. e Liu, R. P. (2020). Survey: Sharding in blockchains. *IEEE Access*, 8:14155–14181.
- [Yue et al., 2016] Yue, X., Wang, H., Jin, D., Li, M. e Jiang, W. (2016). Healthcare data gateways: found healthcare intelligence on blockchain with novel privacy risk control. *Journal of medical systems*, 40:1–8.
- [Zhang et al., 2018] Zhang, P., White, J., Schmidt, D. C., Lenz, G. e Rosenbloom, S. T. (2018). FHIRChain: applying blockchain to securely and scalably share clinical data. *Computational and structural biotechnology journal*, 16:267–278.
- [Zhang e Poslad, 2018] Zhang, X. e Poslad, S. (2018). Blockchain support for flexible queries with granular access control to electronic medical records EMR. Em *2018 IEEE International conference on communications (ICC)*, p. 1–6. IEEE.

Capítulo

5

Nova Geração da Telessaúde: Oportunidades, Tendências e Desafios

Gabriel C. de Almeida, Allan C. N. dos Santos, Celine L. de A. Soares, Paula Caroline A. Pinto, Felipe da S. Dal Bello, Yolanda Eliza M. Boechat, Flávio Luiz Seixas, Alair Augusto S. M. D. dos Santos, Claudio T. Mesquita, Evandro T. Mesquita, Débora C. Muchaluat-Saade e Natalia C. Fernandes

Abstract

This chapter aims to raise the main and newest computational techniques being adopted or envisaged for telehealth, increasing the quality and speed of service to the population. New computing projects applied to telehealth and Brazil's position within this scenario are discussed. A discussion is also presented, raising the positive and negative issues of telehealth, considering ethical and technological issues, and pointing out research challenges in telehealth.

Resumo

Este capítulo visa levantar as principais e mais novas técnicas computacionais que estão sendo adotadas ou vislumbradas para uso em telessaúde, aumentando a qualidade e a velocidade do atendimento à população. São discutidos novos projetos de computação aplicados à telessaúde e o posicionamento do Brasil dentro desse cenário. É apresentada ainda uma discussão levantando as questões positivas e negativas da telessaúde, considerando questões éticas e tecnológicas e apontando desafios de pesquisa em telessaúde.

5.1. Introdução

A Internet revolucionou o mundo moderno de tal modo que uma pessoa que viveu há 100 anos atrás não compreenderia o alcance dessa ferramenta nos dias de hoje. Na sua concepção, jamais se imaginaria o alcance desta tecnologia em todos os campos da atividade humana. Hoje, ela conecta de forma direta ou indireta quase todos os seres humanos, indo do entretenimento a sofisticados trabalhos científicos, passando pela capacidade de gerar riqueza a partir do *home office* e até vivenciar salas inteiras de um museu nas principais cidades do planeta, trazendo contato com todo o conhecimento disponível já produzido pela humanidade. Nesse aspecto, novas tecnologias se desenvolveram e

Este trabalho foi realizado com recursos do CNPq, CAPES, FAPERJ e INCT-MACC.

Os autores são afiliados à Universidade Federal Fluminense (UFF).

foi durante a pandemia da COVID-19 que estas mudanças se impuseram de modo mais significativo, uma vez que as novas tecnologias permitiram, apesar do afastamento social necessário, evitar o isolamento social e manter a assistência em saúde. Desse modo, os sistemas de saúde estão se modificando, surgindo um novo modelo de atendimento que se desenvolve de forma rápida e eficaz, trazendo um grande impulsionamento à telessaúde e ampliando suas atividades dentro da sociedade.

Com as novas tecnologias, profissionais de saúde podem assistir pacientes em áreas remotas ou pouco assistidas, permeando a esse grupo de pessoas acesso a tratamentos antes só alcançáveis nos grandes centros urbanos do país por altos valores. Além disso, novas técnicas vêm sendo introduzidas para acelerar, simplificar e melhorar o atendimento em saúde. A telessaúde não apenas permite a educação em saúde de forma mais eficaz ou o atendimento de áreas remotas, mas novas técnicas para diagnósticos mais rápidos e eficazes, com uso de inteligência artificial, a aplicação de testes e outros tipos de exames usando técnicas como jogos sérios para uma triagem mais eficiente de pacientes.

A telessaúde se tornou popular recentemente, levando muitos a acreditar que seu início ocorreu durante a recente pandemia da COVID-19, mas, na realidade, ela teve início há mais de um século, com embrião em 1910, com a invenção do estetoscópio eletrônico. Durante a 2ª Guerra Mundial, a telemedicina era feita por meio do rádio, de modo a conectar os profissionais da saúde do *front* com os da retaguarda. Mas, somente na década de 1990, a Telemedicina iniciou seu uso em escala mundial. Desde então, a telemedicina tornou-se uma das maiores revoluções na assistência em saúde dos últimos anos, sendo suas normas éticas reconhecidas desde outubro de 1999 na Declaração de Tel Aviv, adotada pela 51ª Assembléia Geral da Associação Médica Mundial [Rezende et al., 2010]. Ela utiliza meios de comunicação eletrônica para transmitir informações e dados médicos de um local a outro, com o objetivo de estender serviços de saúde de centros especializados para regiões que não possuem assistência médica satisfatória. Ela pode trazer soluções tecnológicas e atuar em diversos campos, como na educação interativa, no planejamento da logística, na regulação da assistência e na implementação de métodos no campo assistencial que podem gerar serviços em teleassistência, tediagnóstico, teleprocedimento e na pesquisa multicêntrica. Tais soluções possibilitam trabalhos baseados em estratégias de gestão de sustentabilidade e desenvolvimento de novos modelos de atenção à saúde.

Desde a sua concepção, a telessaúde se revolucionou não apenas nas técnicas computacionais que passaram a ser utilizadas, mas também na modificação de rotinas de saúde. Hoje, suas aplicações vão muito além das teleconferências e troca de mensagens para segunda opinião formativa ou da disponibilização de material educativo para a saúde. Dessa forma, este capítulo visa levantar as principais e mais novas técnicas computacionais que estão sendo usadas ou vislumbradas para uso em telessaúde, aumentando a qualidade e a velocidade do atendimento à população. São discutidos também novos projetos de computação aplicados à telessaúde e o posicionamento do Brasil dentro desse cenário. É feita ainda uma discussão levantando as questões positivas e negativas da telessaúde, considerando questões éticas e tecnológicas e apontando desafios de pesquisa em telessaúde.

O restante deste capítulo está organizado como descrito a seguir. Na Seção 5.2,

são apresentados os principais conceitos de telessaúde e um *overview* das principais atividades no Brasil e no mundo. Na Seção 5.3, são apresentadas aplicações inovadoras em telessaúde, discutindo os campos da teletriagem, teleconsulta, telediagnóstico, telemonitoramento, telerreabilitação e telecirurgia. Na Seção 5.4, são apresentados alguns dos principais projetos em telessaúde pelo mundo, assim como são discutidos os principais desafios de pesquisa. Por fim, a Seção 5.5 apresenta as considerações finais.

5.2. Conceitos Fundamentais de Telessaúde

5.2.1. Visão geral da telessaúde

De acordo com o relatório da Organização Mundial da Saúde (OMS), a telessaúde é um conceito amplo que considera a aplicação de tecnologias tanto para educação à distância quanto para aplicações em que a tecnologia é usada para apoiar os serviços de saúde. Nesse contexto, a OMS coloca a telemedicina, que é parte da telessaúde, sendo definida como a entrega de serviços de cuidados de saúde, nos quais a distância é um fator crítico, desempenhado por todos os profissionais de saúde usando tecnologias de comunicação e informação para a troca de informações válidas para o diagnóstico, tratamento e prevenção de doenças e lesões, no interesse do avanço da saúde dos indivíduos e de suas comunidades. De uma forma mais resumida, trata-se da provisão de serviços de cuidados de saúde remotamente por meios digitais [World Health Organization, 2022].

As modalidades da telemedicina incluem três classes, sendo elas o ‘armazenamento e encaminhamento’, no qual informações de pacientes são enviadas de forma assíncrona à consulta para profissionais de saúde especialistas, usualmente em situações onde não há emergência; ‘serviços interativos’, os quais incluem cuidados em saúde síncronos por meios digitais, com o objetivo de comunicar profissionais de saúde entre si ou com pacientes para diagnosticar e dar assistência; e ‘monitoração de pacientes remota’, também chamada de telemonitoramento, que permite acompanhar o estado do paciente com tecnologias de sensores e dispositivos de saúde conectados à rede. A telemedicina pode acontecer por diferentes meios digitais, tais como vídeo, imagens, áudio, texto, aplicativos e sistemas. Os casos mais comuns de uso incluem a ‘teleconsulta’, que permite o atendimento de pacientes remotos; a ‘teleinterconsulta’ ou ‘segunda opinião formativa’, na qual um profissional de saúde busca pela opinião/orientação de um especialista; a ‘teletriagem’, que permite uma tomada de decisão rápida em casos de emergência pela transmissão de parâmetros de saúde remotamente e pela consulta remota; e a ‘auto-ajuda guiada’, que utiliza intervenções de saúde mental, por meio de informações de autoajuda advindas de textos ou aplicativos associadas ao breve apoio prestado por uma pessoa por telefone ou online [World Health Organization, 2022].

Com a pandemia de COVID-19, houve uma necessidade de regulamentação e concretização dos processos de telessaúde em diversos países do mundo. Por exemplo, na Austrália, foi criada a legislação “*Telehealth Determination*”, que reconhece os serviços de telemedicina e permite a cobrança desses serviços². Cabe destaque que parte dos serviços autorizados na pandemia já não são mais permitidos, enquanto outros foram adotados de forma definitiva. Na Alemanha, foi criado o “*Digital Healthcare Act – DVG*”, que regula o uso de seguro de saúde com telemedicina, emissão de receitas digi-

²<https://www.health.gov.au/topics/health-technologies-and-digital-health/about/telehealth>

tais (*e-prescription*) e define um acesso igualitário aos serviços de saúde digitalizados³. Na Índia, foi lançado o “*Telemedicine Practice Guidelines*”, o qual define algumas regulamentações para a telemedicina, tais como a obtenção de um termo de consentimento do paciente, a garantia de que o atendimento é feito por um médico registrado e a possibilidade de emissão de receitas digitais⁴. Nos Estados Unidos, destaca-se o “*American Medical Association Telehealth Implementation Playbook*”, que guia a implementação de programas de telemedicina de acordo com as políticas regulatórias tais como o “*Health Insurance Portability and Accountability Act of 1996 (HIPAA)*”, além de trazer considerações específicas sobre o monitoramento remoto⁵.

No Brasil, a pandemia trouxe uma série de regulamentações sobre a telessaúde, incluindo a permissão para teleconsultas. Anteriormente à pandemia, apenas teleinterconsultas eram autorizadas, na qual o atendimento remoto de um paciente demandava a presença de um médico em ambos os lados da comunicação. Cabe destaque que, usualmente, as regulamentações em cada país realizam as definições dos termos associados à telessaúde e, eventualmente, surgem pequenas discrepâncias nas definições.

Segundo a resolução do Conselho Federal de Medicina (CFM) n. 2314/2022, entende-se o termo Telessaúde como o uso de Tecnologias de Informação e Comunicação (TIC) para fornecer serviços de saúde à distância, por profissionais de saúde, respeitadas as suas competências legais. Serviços de saúde incluem serviços clínicos, administrativos e educacionais. De acordo com o CFM, a Telessaúde abrange todos os profissionais de saúde, enquanto a Telemedicina é específica da Medicina e portanto, se refere a atos e procedimentos realizados ou sob responsabilidade dos médicos [Brasil, 2022]. Ela pode ser executada em tempo real *online* (de forma síncrona) ou *offline* (de modo assíncrono). Ainda segundo esta resolução, a Telemedicina pode ser exercida nas seguintes modalidades de atendimentos médicos:

- Teleconsulta - Trata-se de uma consulta médica não presencial, realizada por meios de tecnologias digitais da informação e comunicação (TDIC), com médico e paciente em locais diferentes. Entre outras restrições, o médico deverá informar ao paciente as limitações da teleconsulta, dado que não é possível realizar exame físico completo, além de ser necessário um Termo de Consentimento Livre e Esclarecido (TCLE) pré-estabelecido entre o médico e o paciente.
- Teleinterconsulta - Caracterizada pela comunicação entre médicos, por meio de TDICs, com ou sem o paciente, visando suporte diagnóstico, terapêutico, clínico ou cirúrgico. Nessa modalidade, os médicos remotos podem opinar, mas o médico responsável pela teleinterconsulta é o médico responsável pelo acompanhamento presencial do paciente.
- Telediagnóstico - É um ato médico a distância, síncrono ou assíncrono, com transmissão de dados de exame para emissão de laudo ou parecer por um médico especialista na área relacionada ao exame. O local aonde são realizados os exames devem contar com um responsável técnico médico.

³<https://www.bundesgesundheitsministerium.de/digital-healthcare-act.html>

⁴<https://www.mohfw.gov.in/pdf/Telemedicine.pdf>

⁵<https://www.ama-assn.org/system/files/ama-telehealth-playbook.pdf>

- Telecirurgia - Categoria na qual são realizados procedimentos cirúrgicos de forma remota, utilizando equipamento robótico, utilizando técnicas e sistemas de alta resiliência e segurança.
- Telemonitoramento - Também chamado de televigilância, é realizado sob coordenação, indicação, orientação e supervisão médica, visando o monitoramento a distância de parâmetros de saúde e/ou doença do paciente. Inclui a coleta dos dados, a transmissão e o processamento, sem que o paciente precise ir até a unidade de saúde. Esses dados podem ser obtidos por avaliação clínica e/ou aquisição direta de imagens, sinais e/ou dados de outra natureza. Os dados adquiridos podem ser provenientes de equipamentos, dispositivos agregados ou dispositivos implantáveis em pacientes.
- Teletriagem - Trata-se da avaliação dos sintomas de um paciente à distância por um médico com objetivo de regulação ambulatorial ou hospitalar, permitindo o direcionamento adequado do paciente ao tipo de assistência de que necessita ou a um especialista. É importante destacar que trata-se de uma impressão inicial diagnóstica e de gravidade, sem se caracterizar como uma consulta.
- Teleconsultoria - Consiste da consultoria por TDICs entre médicos, gestores e outros profissionais para troca de informações sobre procedimentos administrativos e ações de saúde.

Cabe destaque que a telessaúde também é regulamentada para outros profissionais de saúde, tais como a telefarmácia (Resolução N° 727/2022⁶), tele-enfermagem (Resolução RESOLUÇÃO COFEN N° 696/2022⁷) e telefisioterapia (COFFITO RESOLUÇÃO N° 516, DE 20 DE MARÇO DE 2020⁸).

5.2.2. Telessaúde no Brasil

No Brasil, diante das pressões sociais vividas na década de 1980, foi promulgada a constituição de 1988, na qual o artigo 196 garante a criação do SUS (Sistema Único de Saúde). Este foi promulgado em 1990 pela lei n° 8080, tendo como princípios básicos a universalização de acesso, a integralidade da atenção, a equidade, a descentralização da gestão, a hierarquização dos serviços e o controle social da saúde. Dentre estes princípios, a universalidade do acesso à saúde vem sendo questionada pois, nas últimas décadas observa-se precariedade de profissionais, principalmente especialistas, em diversas áreas da saúde em nosso país, que por suas dimensões continentais apresenta barreiras geográficas, sociais e econômicas que permeiam desproteção a uma parcela da população.

Na Constituição de 1988, assegura-se, em seu artigo V, direitos invioláveis ao paciente, como o sigilo, a privacidade e a liberdade de escolha. O Código de Ética Médica (CEM), promulgado pelo Conselho Federal de Medicina (CFM) também em 1988, preconizou que o profissional não deve prescrever tratamentos sem antes consultar o paciente (Artigo 62); revelar nenhum dado do paciente sem o seu consentimento (Artigo

⁶<https://cff-br.implanta.net.br/PortalTransparencia/Publico/ArquivosAnexos/Download?idArquivoAnexo=5dba34b5-26e8-4ece-8b14-7ee57e105334>

⁷http://www.cofen.gov.br/resolucao-cofen-no-696-2022_99117.html

⁸<https://www.coffito.gov.br/nsite/?p=15825>

102); expor o caso clínico e a identidade do paciente (Artigo 104); facilitar o manuseio do prontuário por pessoas não comprometidas eticamente com o caso (Artigo 108); dar consulta, diagnóstico ou prescrição por intermédio de qualquer veículo de comunicação de massa (Artigo 132). Desta forma, havia muitas exigências para que o uso da tecnologia pudesse ser utilizado nas práticas de saúde. Contudo, aos poucos foram surgindo orientações que permeariam esta atividade.

Em 2002, o CFM criou as primeiras legislações brasileiras para a regulamentação da telemedicina no país, sendo organizado o Conselho Brasileiro de Telemedicina e Telessaúde, marco legal fundamental para a existência da telessaúde no país. Nesta mesma época, o CFM emitiu resolução que definiu e disciplinou a prática e a prestação de serviços nesta modalidade de atendimento.

Em 2002, o CFM aprovou a resolução nº 1639/2002 que definiria as “Normas Técnicas para o Uso de Sistemas Informatizados para a Guarda e Manuseio do Prontuário Médico” e, em 2004, no artigo primeiro da resolução nº 1718/2004, ele restringe as ações, apontando que médicos não devem ensinar procedimentos para profissionais de outras áreas da saúde, exceto em casos de emergência, por meio da Telemedicina.

Cabe destaque que, em 2006, a Organização Mundial de Saúde já recomendava o uso da Telemática na estratégia de planejamento de saúde [Craig e Patterson, 2005]. A Telemática era então definida como a disciplina que estuda a manipulação e a utilização da informação pelo uso de computador, seus acessórios e meios de comunicação. A telemática envolve qualquer meio de comunicação à distância, podendo ser utilizada de forma a propiciar informações sobre saúde. Posteriormente, iniciou-se o uso do termo Telemedicina para a Telemática para a saúde, em uma fase mais inicial, e posteriormente, Telessaúde, considerando que as práticas de saúde à distância por meios computacionais não se restringiam apenas à medicina. Desde 2000, o termo e-Saúde (*e-Health*) também passou a ser utilizado como um sinônimo.

Em 2003, o Ministério da Saúde criou a Política Nacional de Informação e Informática em Saúde (PNIIS) com o objetivo de promover o uso inovador, criativo e transformador das tecnologias para melhorar os processos de trabalho em saúde.

Um dos primeiros marcos de relevância nacional foi o lançamento do Edital do Programa “Institutos do Milênio” do CNPq em 2005, que indicava a telemedicina como uma demanda e mostrava a visão governamental da telessaúde como um campo estratégico. Dentro desse contexto, surge o Projeto de Telemedicina “Estação Digital Médica” (EDM-Milênio). Esse projeto era um consórcio entre nove universidades e institutos de pesquisa, visando a consolidação da telemedicina no Brasil, com iniciativas de tutoria eletrônica e ambulatórios virtuais. Um segundo marco relevante foi a criação do Projeto de Telemática e Telemedicina em apoio à Atenção Primária no Brasil, por iniciativa do Ministério da Saúde em 2005. Nesse projeto, formaram-se nove núcleos, incluindo quatro oriundos do Projeto de Telemedicina do Milênio, com o objetivo de implantar 900 pontos de atendimento de atenção primária com soluções tecnológicas do EDM-Milênio. Entre as ações visadas, tinha-se a Teleducação Interativa, a Segunda Opinião Especializada Formativa, além da formação de uma Biblioteca Virtual em Saúde [Wen, 2008]. Em 2006, o Ministério da Saúde cria a Comissão Permanente de Telessaúde e o Comitê Executivo de Telessaúde e, em 2007, o Programa Nacional de Telessaúde [Brasil, 2007].

O terceiro marco de ações governamentais no Brasil, e de grande relevância, foi a criação do projeto da Rede Universitária de Telemedicina (RUTE) da RNP (Rede Nacional de Ensino e Pesquisa), em 2006 [Silva e Moraes, 2012, Brito et al., 2016]. A Rede RUTE criou uma infraestrutura entre os hospitais universitários e unidades de ensino em saúde no Brasil para realização de videoconferências entre profissionais de saúde, possibilitando atividades educacionais e assistenciais em saúde, em uma época que a telessaúde ainda era muito incipiente no Brasil. A Rede RUTE é um dos principais marcos do início em mais larga escala da telessaúde no Brasil [Messina et al., 2014].

Seguindo a linha de planejamento estratégico para implantação de um ambiente de Saúde Digital no Brasil, em 2007, o Ministério da Saúde criou o Programa Nacional Telessaúde Brasil Redes (Portaria do Ministério da Saúde nº 35 de janeiro de 2007, redefinido e ampliado pela Portaria MS nº 2.546, publicada no dia 27 de outubro 2011). Sendo um marco da popularização da telessaúde no Brasil, esse projeto visa fortalecer e melhorar a qualidade do atendimento da atenção básica no Sistema Único de Saúde (SUS). Entre as ações estratégicas, tem-se a Educação Permanente em Saúde (EPS) e o apoio assistencial por meio de ferramentas e Tecnologias da Informação e Comunicação. Esse Programa, ativo até os dias de hoje, é constituído por Núcleos Estaduais, Intermunicipais e Regionais.

Em 2010, o Ministério da Saúde elaborou o componente de Informatização e Telessaúde Brasil Redes na Atenção Básica, integrado ao Programa Nacional Telessaúde Brasil Redes [Lisboa et al., 2023]. Na prática, a proposta era informatizar as Unidades Básicas de Saúde (UBS), estabelecendo conectividade entre essas unidades e os pontos de atenção integrantes da Rede de Atenção à Saúde. Outras ações estimulavam, por meio de incentivos financeiros, a criação de mais Núcleos de Telessaúde estaduais e intermunicipais [Maldonado et al., 2016].

É importante destacar que, até 2019, a telemedicina era regulada pelo CFM, mas sem descrições detalhadas de modalidade. O uso da telemedicina gerava grandes discussões considerando a qualidade das consultas e o custo dos serviços em saúde. Em fevereiro de 2019, o CFM autorizou aos médicos a realização de consultas *online*, assim como telecirurgias e telediagnóstico. Contudo, em fevereiro do mesmo ano, essa resolução foi revogada [Lisboa et al., 2023]. Nesse sentido, apenas a teleinterconsulta era autorizada e mais amplamente utilizada, em especial com o apoio da Rede RUTE, além do telediagnóstico.

A grande revolução da telessaúde no Brasil, assim como no resto do mundo, ocorreu em 2020, com o surgimento da pandemia de COVID-19. Com o isolamento social, a quarentena de doentes e o medo generalizado na população, se fizeram necessárias novas formas de atendimento em saúde. Contudo, essa necessidade se deu de forma emergencial e com pouquíssimos sistemas disponíveis adequados às atividades. Nessa época, surgiram regulamentações temporárias, as quais foram revistas após o amadurecimento dos processos. Dessa forma, em março de 2020, o CFM autorizou a telemedicina “em caráter de excepcionalidade” (OFÍCIO CFM Nº 1756/2020 – COJUR), nas modalidades de: teleorientação, nos quais médicos poderiam orientar e encaminhar pacientes a distância devido ao isolamento; telemonitoramento; e teleinterconsulta. Em abril de 2020, é promulgada a Lei nº 13.989/2020, autorizando todas as atividades da área de telemedicina,

incluindo a teleconsulta, até o final da pandemia⁹. Também em março de 2020, a Agência Nacional de Saúde Suplementar (ANS) regulamentou o uso de telessaúde pelas seguradoras e prestadores de serviço de saúde. Com isso, outros profissionais de saúde, além dos médicos, ficavam autorizados a atuarem por meio de telessaúde, ficando a regulamentação das atividades a cargo dos conselhos federais específicos. Em abril, a ANS obrigou os planos de saúde a cobrirem consultas realizadas por meios digitais [Lisboa et al., 2023].

A Figura 5.1 traz uma linha do tempo com os principais marcos da história da telessaúde no Brasil.

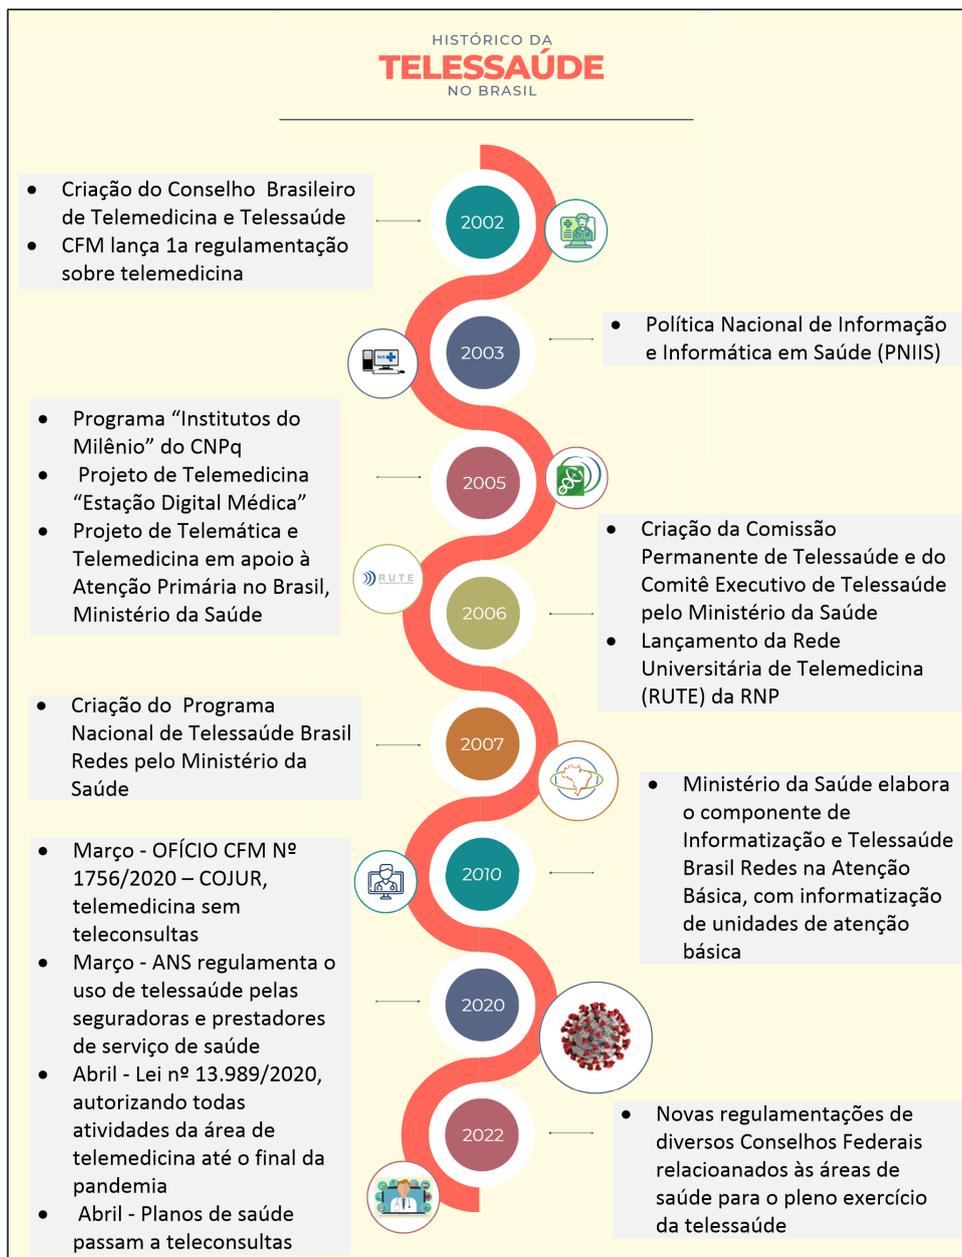


Figura 5.1. Evolução cronológica das ações de telessaúde no Brasil.

⁹<https://www.in.gov.br/en/web/dou/-/lei-n-13.989-de-15-de-abril-de-2020-252726328>

5.2.3. Iniciativas atuais em telessaúde no Brasil

A telessaúde vem tendo uma importante evolução e consolidação no Brasil nos últimos 5 anos com o incentivo de agências de fomento à pesquisa e com as ações governamentais que possibilitaram a formação de equipes e núcleos de pesquisa em diversas instituições universitárias brasileiras como a Universidade de São Paulo (USP), a Universidade Federal do Rio Grande do Sul (UFRGS), a Universidade Federal de Santa Catarina (UFSC), a Universidade Estadual do Rio de Janeiro (UERJ), a Universidade Federal Fluminense (UFF) e outras. Entre as iniciativas, em Santa Catarina, já se pratica o uso da telessaúde dentro do processo regulatório do estado, ou seja, ações de telessaúde fazem parte da rotina para a organização da fila de pacientes para o encaminhamento de unidades básicas de saúde para hospitais de referência. O Hospital Universitário Pedro Ernesto, da Universidade do Estado do Rio de Janeiro, foi o primeiro no estado do Rio de Janeiro a prover teleconsultas dentro do contexto do SUS¹⁰. Essas e outras atividades dentro do campo da telessaúde trazem desenvolvimento dentro da Medicina e de outras áreas, especialmente na área da tecnologia aplicada à saúde. Ela otimiza a educação, o planejamento logístico, a regulação da assistência e a implementação de métodos para proporcionar pesquisas multicêntricas, baseadas em estratégias de gestão de sustentabilidade. Diversas aplicações para a telemedicina já estão em uso nos campos da telerradiologia, telepatologia, tele dermatologia, tele oftalmologia, telecirurgia e outras. Algumas experiências de sucesso são a Rede RUTE; os serviços de Telecardiologia do Instituto do Coração do Hospital das Clínicas da Universidade de São Paulo, desde 1994; e o programa de Segunda Opinião por videoconferência com consulta conjunta entre a equipe médica do Centro de Oncologia do Hospital Sírio-Libanês. Outros usos são o projeto de assistência às regiões ribeirinhas de Santa Catarina no rio Madeira em Rondônia; a assistência médica como palestras sobre prevenção em saúde pela Universidade Federal do Rio Grande do Sul; a videocolaboração do laboratório PRAV (Projetos em Áudio e Vídeo) pelo sistema de webconferência Mconf; a Sala Cirúrgica Multimídia e Mobilicare, com tecnologias de baixo custo nacionais, voltada para assistência à distância; e o Projeto de Telessaúde por Holografia da Universidade Federal Fluminense, que visa o atendimento em saúde da população da Região Norte do país.

5.2.4. Desafios práticos da telessaúde

Existem alguns desdobramentos importantes para a utilização plena da Telessaúde, que podem se tornar verdadeiros impeditivos para a aplicação das diversas modalidades de atenção à saúde. Entre esses, destacam-se:

- Acesso à Internet - As técnicas de telessaúde, em especial as síncronas, dependem de uma conexão estável e com um mínimo de qualidade de serviço. Contudo, ao se observar as unidades de atendimento públicas no Brasil, muitas ainda não estão sequer digitalizadas, além de não contarem com uma boa conexão com a Internet em todos os seus consultórios. A situação é ainda mais crítica em municípios mais afastados e pobres. Considerando os casos em que o paciente precisa estar conectado, essa situação pode gerar ainda mais exclusão social, pois boa parte da população não possui equipamentos sofisticados ou com acesso à Internet de qualidade.

¹⁰<https://www.uerj.br/agenda/hupe-lanca-sistema-de-teleconsulta-para-usuario-do-sus/>

- **Segurança da informação** - A guarda de dados médicos é um ponto crítico dentro dos processos de digitalização em saúde. A gestão dos dados deve dar suporte dentro do que preconiza a Lei Geral de Proteção de Dados (LGPD), garantindo o acesso dos dados armazenado apenas para profissionais que estejam, de fato, lidando com o paciente. Além disso, os pacientes devem ter direito à gestão de seus prontuários [de Medeiros et al., 2022]. Outro problema grave é relacionado às vulnerabilidades dos sistemas de computação utilizados, podendo levar ao vazamento de dados privados.
- **Inclusão digital dos pacientes** - Para participação em muitos processos de tele-saúde, o paciente precisa estar apto a utilizar com destreza equipamentos digitais, o que pode não ser verdade para os pacientes com baixa instrução ou com mais idade.
- **Profissionais habilitados para troca via digital** - Assim como os pacientes precisam estar aptos a lidar com os meios digitais, os profissionais de saúde precisam conhecer os sistemas, saber utilizá-los e se sentirem confortáveis com a tecnologia, para que ela não venha a atrapalhar as ações do profissional.
- **Conhecimento dos limites técnicos para a aplicação da telessaúde** - A equipe de saúde deve conhecer protocolos e procedimentos que podem ser aplicados na telessaúde, assim como deve conhecer as limitações desses tipos de prática, evitando colocar em risco o paciente por um abuso no uso da telessaúde, tais como diagnosticar por teleconsulta um paciente que precisa de exame físico.

5.3. Propostas de Nova Geração em Telessaúde

A telessaúde está em forte evolução, migrando de um modelo que apenas incluía a comunicação entre profissionais ou com pacientes, além do envio de exames para laudos, para um modelo mais amplo e complexo. Novas soluções tecnológicas vêm sendo aplicadas, incluindo inteligência artificial, multimídia, jogos sérios, entre outros, visando serviços de nova geração que podem ser realizados em algumas das diversas modalidades da telessaúde. Esta seção visa apresentar essas novas soluções, descrevendo o seu potencial impacto nos serviços de saúde.

5.3.1. Propostas para Teletriagem

A demanda em salas de emergência é usualmente muito alta, mesmo em hospitais particulares [Bhatt e Bhatt, 2021, Latifi et al., 2020]. Estudos mostram que médicos consideram que a maior parte dos primeiros atendimentos em clínicas primárias não precisariam ser ao vivo e um quarto dos atendimentos de emergência poderiam aguardar o atendimento clínico habitual do paciente [Acevedo et al., 2022, Bhatt e Bhatt, 2021]. Com isso, surgiu o campo da teletriagem, que visa selecionar os casos que precisam de atenção imediata presencial. A teletriagem é uma técnica de triagem médica que usa a tecnologia de telecomunicações para permitir que os profissionais de saúde pré-examinem remotamente os pacientes [Choudhury et al., 2022, Bhatt e Bhatt, 2021]. Esse tipo de serviço já é consolidado por meio telefônico em muitos países europeus, já há algumas décadas [Acevedo et al., 2022]. Recentemente, vem sendo utilizado tanto por meios de voz quanto de vídeo.

Essa experiência de pré-avaliação remota cada vez mais vem se expandindo, por meio de avaliações à distância que podem ser tanto mediadas por profissionais de saúde, caracterizadas como teletriagem, quanto, muitas vezes, realizadas pelos próprios pacientes, caracterizada como uma auto-ajuda guiada [Latifi et al., 2020, Choudhury et al., 2022], em uma modalidade de auto-atendimento. Tais experiências são cada vez mais comuns na parte de neurociência, onde já se observam tanto os ganhos, como a detecção mais rápida de alguns males ou o rápido levantamento de dados, como os prejuízos, causados pela aplicação dos testes cognitivos de forma incompleta ou não ajustada ao perfil do paciente [Gagné e Franzen, 2023]. Esta seção visa apresentar e discutir novas tecnologias aplicadas à teletriagem e seus impactos.

5.3.1.1. Uso de inteligência artificial na teletriagem

Recentemente, foram desenvolvidas diversas propostas que aplicam técnicas de inteligência artificial (IA) e de aprendizado de máquina na teletriagem, revolucionando as possibilidades nesse modalidade da telessaúde. A IA pode desempenhar um papel importante na teletriagem, ajudando a automatizar e aprimorar a classificação dos pacientes quanto à gravidade, ao nível da emergência e à necessidade ou não de um atendimento presencial.

A Figura 5.2 mostra uma classificação proposta por Salman et al. com os desafios relacionados a teletriagem e o uso do aprendizado de máquinas [Salman et al., 2021]. De acordo com os autores, o atendimento de urgência e emergência tem crescido consideravelmente devido ao envelhecimento da população e ao crescimento sobre o conhecimento e monitoramento de doenças crônicas, o que leva a uma superlotação dos hospitais. Para reduzir essa lotação, técnicas de aprendizado de máquina podem ser utilizadas, considerando tanto aprendizado supervisionado quanto o não supervisionado, permitindo uma melhor triagem e priorização dos pacientes. Contudo existem diversos desafios em aberto, relacionados com a predição correta de doenças; a detecção correta dos níveis de emergência com base nas principais queixas; a capacidade de classificação dos algoritmos; o consumo de tempo até a emissão de um parecer pelo algoritmo e, principalmente, para o treinamento e atualização das redes; o consumo de energia; a segurança e a privacidade dos dados dos pacientes; as etapas do processamento de dados; e o desenvolvimento de novos sistemas para dar o adequado suporte à aplicação das novas tecnologias.

Aplicações práticas dessas técnicas são descritas em estudos de caso em vários locais do mundo. Por exemplo, na Alemanha, em 2020, foi desenvolvido um sistema de triagem por telefone baseado em um software de suporte a decisão com relação ao nível de urgência e ao nível apropriado de atendimento que o paciente demanda. O sistema é chamado de “*Strukturierte medizinische Ersteinschätzung in Deutschland*” (SmED) e foi desenvolvido sobre um sistema suíço pré-existente [von Stillfried, 2021].

Outro uso muito interessante da IA em teletriagem por telefone é a aplicação desenvolvida por Iyer et al., que utiliza IA em ligações de triagem em saúde mental para detecção de potenciais suicidas [Iyer et al., 2022]. Esse tipo de atividade é de grande importância e dificuldade, pois pequenas nuances apresentadas pelo paciente podem não ser detectadas pelo profissional de saúde, colocando a pessoa em risco. Nesse sentido, a

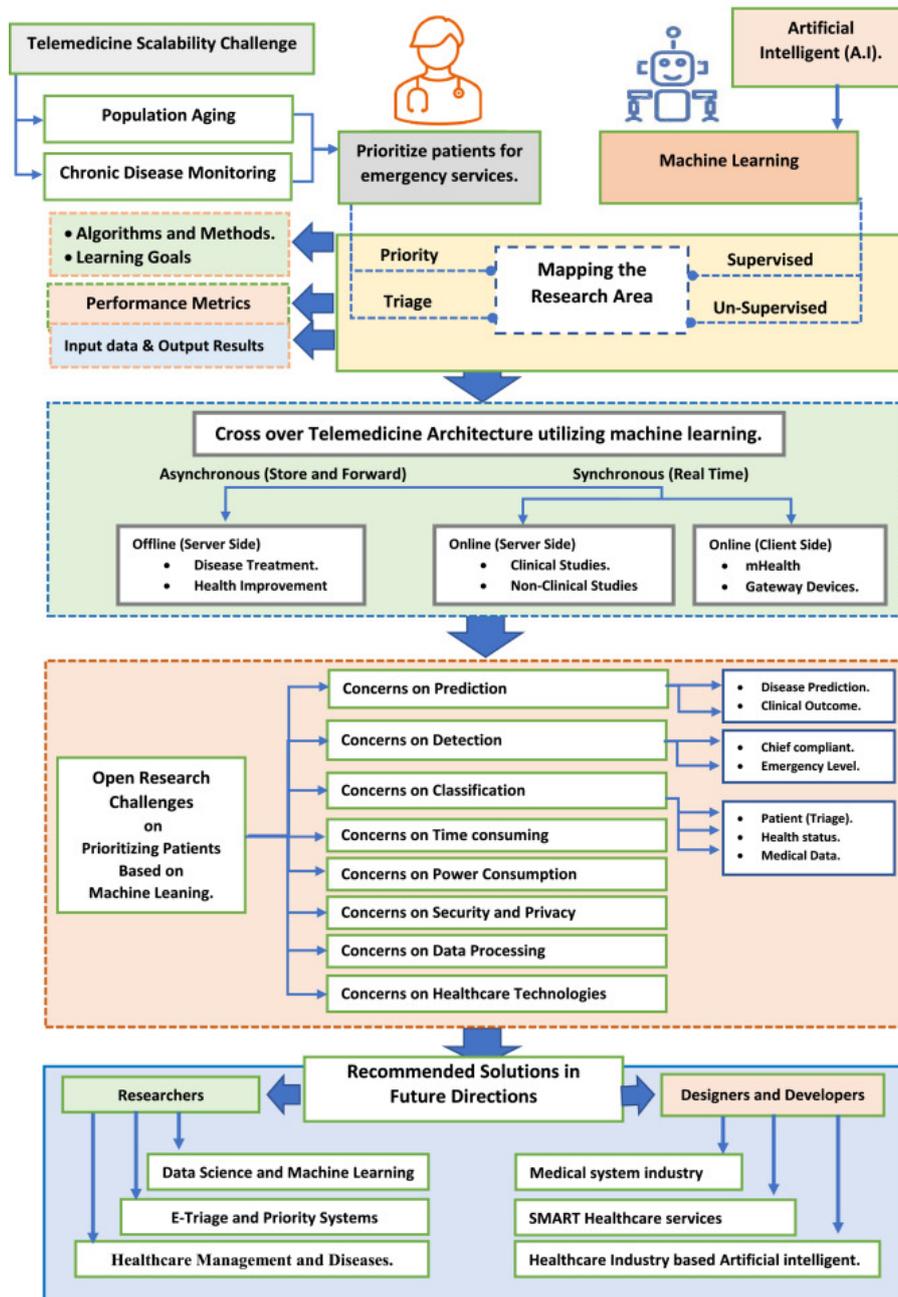


Figura 5.2. Arcabouço de revisão de literatura desenvolvido por Salman et al. para identificação da aplicação de inteligência artificial nos processos de teletriagem, considerando as fases de triagem e priorização de emergências. Fonte: [Salman et al., 2021].

IA tem o potencial de inovar as práticas atuais para detectar o risco iminente de suicídio, dando indicações de potenciais riscos para o profissional de saúde e ajudando a superar deficiências nos métodos tradicionais de avaliação. O método utilizado pelos autores consiste em classificar automaticamente segmentos curtos de 40 milissegundos de fala em risco baixo ou risco iminente de suicídio. Para treinar o algoritmo de classificação, foram utilizadas 281 chamadas telefônicas feitas para serviços de aconselhamento de telessaúde

na Austrália, chamados de *On The Line* e Canberra. O pré-processamento envolveu a normalização e pré-ênfase dos sinais de voz, enquanto a biometria da voz foi extraída usando a linguagem estatística R. Cada biomarcador de voz foi avaliado como um preditor de risco de suicídio usando um modelo aditivo generalizado de efeitos mistos com *splines* para lidar com a não linearidade dos sinais. Por fim, um modelo de *gradient boosting* foi usado para classificar cada gravação [Iyer et al., 2022]. Os resultados mostram que o procedimento de avaliação médica inicial SmED transfere apenas 25% dos pacientes para a sala de emergência.

Outras ferramentas utilizam aprendizado de máquina em testes cognitivos online, visando a detecção de doenças mentais, ajudando na detecção do problema e triagem para profissionais de saúde especializados. Grazioli et al mostraram que questionários em plataformas online preenchidos por pais e professores podem ser utilizados para detecção de déficit de atenção/hiperatividade (TDAH) e transtornos do espectro autista (TEA) [Grazioli et al., 2023]. Os autores utilizaram questionários online coletados remotamente em uma avaliação no local de quocientes de inteligência de 342 indivíduos, sendo apenas 18% mulheres, com idades entre 3 e 16 anos, encaminhados por suspeita de TDAH. Utilizou-se um modelo de árvore de decisão (*Decision Tree* - DT) para classificação de TDAH/não TDAH com base nos dados coletados. O modelo treinado identificou as regras de decisão que os médicos adotam para classificar um diagnóstico de TDAH com uma taxa de precisão de 82%. No entanto, os sintomas de TEA foram um fator de confusão quando a gravidade do TDAH teve que ser estabelecida. O estudo mostrou que os procedimentos de tele-saúde se mostraram eficazes na obtenção de uma saída automatizada, reduzindo o tempo de atraso entre a detecção do sintoma e o diagnóstico. No entanto, os autores deixam claros que esse tipo de abordagem ajuda na triagem, mas não serve como diagnóstico definitivo para a doença.

Uso de chatbots na teletriagem e no auto-triagem

Outra técnica que ficou muito popular na ajuda para teletriagem e auto-triagem é o uso de chatbots para a saúde. Os chatbots alimentados por IA podem ser usados para interagir com os pacientes e coletar informações sobre seus sintomas. Esses chatbots podem fazer perguntas relevantes, como histórico médico, sintomas atuais e fatores de risco, e fornecer orientações iniciais com base nas respostas dos pacientes.

Ganapathy et al desenvolveram um sistema baseado em chatbot para teletriagem e orientação pediátrica [Ganapathy et al., 2023]. Quando uma criança fica doente, os pais se preocupam com a gravidade potencial da doença e levam as crianças para os serviços de emergência. Contudo, dependendo da apresentação, natureza e duração das queixas, muitas dessas condições pediátricas agudas poderiam ser tratadas e monitoradas em casa ou por profissionais de saúde primários na comunidade. Situações mais adversas ocorrem quando cuidadores e pais muitas vezes recorrerem à Internet para obter informações rápidas sobre como tratar a doença da criança, mas acabam sendo inundados com informações de saúde nem sempre confiáveis, sem conseguir esclarecer suas preocupações e dúvidas. Com isso, as famílias acabam em frequentes atendimentos pediátricos na emergência, apenas para ter a grande maioria classificada como casos ‘não urgente’ após triagem, enfrentando grandes filas até o atendimento. Dessa necessidade surgiu a ideia da linha de ajuda para triagem médica aguda para cuidadores de crianças.

Nesse contexto, existe um estudo de caso interessante de Singapura com o uso de chatbots para atendimento pediátrico. Inicialmente, o *KK Women's and Children's Hospital* (KKH) disponibilizava uma linha telefônica com o serviço em tempo real chamado de *'Ask-A-Nurse'*, que fazia atendimentos de triagem e esclarecimento de dúvidas, com cerca de 30 a 50 chamadas por dia. Por problemas orçamentários, esse serviço precisou ser descontinuado, levando o hospital a buscar parcerias para desenvolvimento de um chatbot que substituísse, ainda que parcialmente, o serviço. O projeto objetivava prover um telessuporte seguro e acessível a toda a comunidade, além de um serviço de triagem automatizado, capaz de estimar o tipo de atendimento necessário, recomendando a ida ao hospital em casos pediátricos classificados como agudos e urgentes. Em 2019, o projeto, que já reunia iniciativa privada e pública, disponibilizou o KKH-Urgent Pediatric Advice Line (KKH-UPAL), um software de teletriagem para casos pediátricos visando reduzir atendimentos não-urgentes e não-emergentes no hospital. Como consequência do uso do sistema, observou-se a redução de filas de espera, além da redução do risco de contaminação das crianças e seus familiares por estarem expostos desnecessariamente no hospital. Outra consequência positiva é que os médicos passaram a poder investir mais tempo nas consultas mais graves, uma vez que a fila de espera não era excessivamente grande.

A primeira *release* do KKH-UPAL era um chat baseado em texto que permitia que responsáveis fizessem perguntas sobre condições da criança e listassem os principais sintomas observados na criança. Além disso, era possível enviar fotos. Nessa primeira versão, não existia o chatbot, mas enfermeiros e profissionais de saúde que avaliavam os casos e respondiam. Os dados obtidos nessa fase foram utilizados para treinar o chatbot, o qual é baseado em um algoritmo de aprendizado de máquina supervisionado para processamento de linguagem natural (*Natural Language Processing* - NLP), e foi disponibilizado na versão lançada em 2020. A Figura 5.3 mostra o fluxo de atividades do chatbot. Quando um usuário faz uma pergunta, a pergunta é processada pelo NLP, que funciona como o “cérebro” do chatbot, o qual retorna uma resposta. Se uma resposta adequada não for encontrada, o chatbot pesquisa em uma base de conhecimento médico pré-preparada de perguntas frequentes. Se isso também falhar, a pergunta é encaminhada para o profissional de saúde.

O chatbot passou a ser o primeiro ponto de contato com pacientes, indicando alguns cuidados paliativos para condições que eram não emergentes, e, nesses casos, recomendando uma visita a um médico de atenção básica. Em casos detectados como mais graves, era recomendada a ida ao hospital para o atendimento de emergência. Eventualmente, quando o chatbot não conseguia atender às requisições sendo feitas, a conversa era transferida para um profissional de saúde. Durante o período em que o software foi avaliado, observou-se que o chatbot conseguiu tratar sozinho 96% das requisições, o que significa que cerca de apenas 4 a 6 requisições eram encaminhadas para o setor de enfermagem.

Cabe destaque que esse tipo de abordagem se fez evidente em diversas partes do mundo, levando à criação de diferentes sistemas para teletriagem pediátrica. Nesse contexto, Espinoza et al disponibilizam um conjunto de diretrizes para a criação de chatbots para teletriagem pediátrica [Espinoza et al., 2020]. Contudo, é importante observar que o bom funcionamento de um chatbot depende da disponibilização de um bom conjunto de dados que mapeie de forma adequada os tipos de requisições usualmente feitos, com um

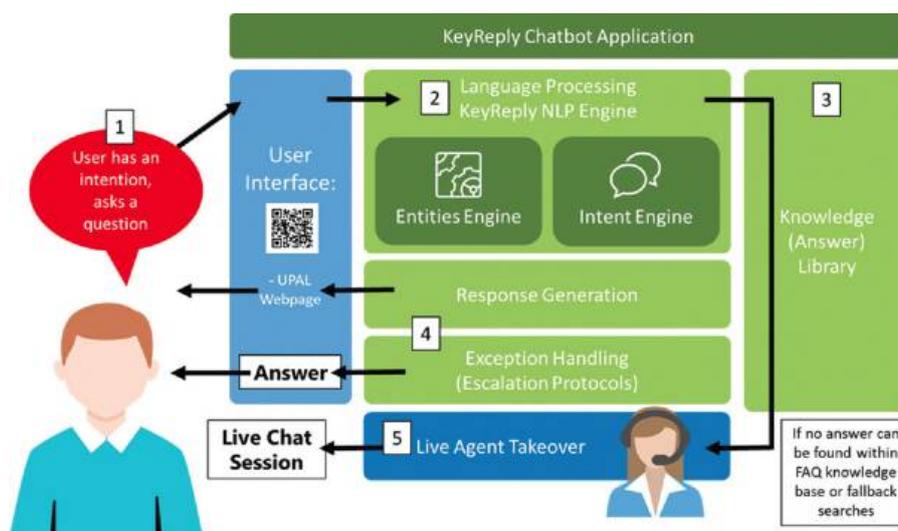


Figura 5.3. Fluxo de atendimento com o chatbot KKH-UPAL, de Singapura. Fonte: [Ganapathy et al., 2023].

bom mapeamento da linguagem utilizada pela população que utiliza o serviço.

Quando se trata de chatbots para auto-triagem, os casos mais comuns encontrados na literatura são os sistemas desenvolvidos para triagem dos casos de COVID-19, indicando se os sintomas dos pacientes são os típicos da doença e se o paciente deve ou não procurar um serviço de emergência [Morse et al., 2020, Reid et al., 2020, Chagas et al., 2021, Cateb et al., 2021, de Campos Filho et al., 2022]. Sobre essas experiências desenvolvidas rapidamente impulsionadas pelo agravamento da pandemia, Reid et al. apresentam uma entrevista com a diretora do Providence Health, um hospital de referência em Washington, onde é descrito como foi a modificação do chatbot do hospital para fazer a triagem de pacientes com COVID-19 [Reid et al., 2020]. A direção do hospital observou, com o aumento dos casos e a necessidade de isolar pacientes contaminados, que a forma mais inteligente de tratar o problema seria por uma triagem remota. Aproveitando o chatbot já existente no hospital, chamado de Grace, o hospital se uniu com a Microsoft para atualizar o Grace com entradas clínicas sobre a COVID-19, além de perguntas e respostas frequentes sobre a doença.

No Brasil, também ocorreram diversas iniciativas, de tal forma que desde hospitais até órgãos governamentais acabaram disponibilizando ferramentas para orientar a população e mapear os casos [Chagas et al., 2021, Cateb et al., 2021, de Campos Filho et al., 2022]. Por exemplo, em Minas Gerais, foi desenvolvido o TeleCOVID Chatbot. Essa solução provê tanto um módulo para perguntas e respostas, quanto a teletriagem em si, classificando os usuários em cinco classes, de acordo com a severidade dos sintomas descritos pelo usuário [Chagas et al., 2021].

Outros exemplos comuns são os chatbots para teleorientação e triagem de pacientes com problemas de saúde mental decorrentes dos efeitos da pandemia. Jackson-Triche et al. fornecem uma descrição detalhada do projeto e implementação de chatbot para triar e facilitar o acesso à avaliação e tratamento de saúde comportamental para a profissionais de saúde de um grande centro médico acadêmico durante a pandemia [Jackson-Triche et al.,

2023]. Esse software foi usado no programa *University of California, San Francisco Coping and Resiliency* (UCSF Cope). O UCSF COPE fornecia acesso a suporte emocional e cuidados de saúde comportamental para todos os professores, funcionários e estagiários, combinando uma abordagem de saúde populacional com tecnologia de chatbot para triagem, avaliação e tratamento. A lógica do chatbot triava os usuários em encaminhamento de emergência/urgente (risco de suicídio, risco para outras pessoas, perigo para a criança); sofrimento leve a moderado; novo início de sintomas moderados a graves; ou possível exacerbação ou recaída para aqueles com comportamento pre-existente de distúrbio de saúde. Após a classificação, o software direcionava o usuário para uma variedade de serviços e materiais baseados em evidências, incluindo o encaminhamento para o serviço de emergência 911 ou linhas diretas, de acordo com o tipo de caso [Jackson-Triche e Mangurian, 2022].

Pode-se observar que a pandemia popularizou e levou a melhorias expressivas nos chatbots para a saúde. Com isso, após a pandemia, o uso dos chatbots acabou se expandindo para novas áreas de atendimento. Por exemplo, Siddiqi e PiuZZi descrevem uma iniciativa pós-pandemia que usa chatbots para realizar uma triagem de pacientes que precisam de cirurgia ortopédica [Siddiqi e PiuZZi, 2021]. Os usos são os mais diversos, trazendo ganhos tanto para os hospitais quanto para os pacientes.

Contudo, o uso de chatbots, embora possa trazer economias, nem sempre é a melhor opção, muito embora seja capaz de reduzir custos e acelerar atendimentos prioritários. Um exemplo de estudo sobre o uso de chatbots na saúde não ligado a teletriagem, mas à teleorientação, é apresentado por Kim et al [Kim et al., 2021]. Em seu estudo, os autores abordam o caso da eficácia dos chatbots para orientação contra a hesitação vacinal na COVID-19. O objetivo do estudo era comparar um chatbot com um recrutamento baseado em telefone. Os adultos que receberam as ligações ou o contato por chatbot foram aleatoriamente selecionados e, em ambos os casos, se requisitava o consento no entrevistado para participar dessa pesquisa. Observou-se que as respostas ao contato foram significativamente menores (cerca de 21% a menos) com o chatbot do que com as ligações. Além disso, a taxa de aceitação em participar da pesquisa também foi menor com o chatbot (cerca de 3,4% a menos). Isso demonstra que existe uma receptividade menor para ações realizadas com robôs, o que pode vir a afetar a efetividade dos sistemas baseados em chatbots em alguns casos.

Outra questão relevante é como tratar os erros de triagem ou de orientação. Esses erros podem levar a consequências graves e levar a questionamentos sobre responsabilização. Essa situação é especialmente mais preocupante quando esses sistemas são utilizados com populações com baixo nível de escolaridade, com dificuldades de comunicação escrita.

5.3.1.2. Uso de realidade aumentada na triagem

Outra ferramenta de nova geração que vem sendo citada no contexto de triagens é a realidade aumentada. Na realidade aumentada, a imagem do mundo real é sobreposta com dados gerados artificialmente. Entre os dispositivos mais comumente utilizados tem-se os celulares e óculos inteligentes.

Park et al propõem o uso de realidade aumentada no telediagnóstico de feridas por queimadura [Park et al., 2022]. A principal justificativa é que médicos generalistas usualmente falham em 40% dos diagnósticos sobre a profundidade de queimaduras, gerando erros graves nos tratamentos. Contudo, feridas por queimadura, além de malignidades cutâneas e infecções de pele, são altamente passíveis de análise e tratamento por imagens, devido à sua natureza visível, facilidade de reprodução de imagens e necessidade de monitorar o progresso como parte do tratamento. Algumas limitações para esses métodos advêm da qualidade da imagem, da habilidades reduzida de alguns profissionais para avaliar profundidade e gravidade da lesão com imagens estáticas e frequência de comunicação. A comunicação frequente é necessária para o tratamento, que requer constante avaliação das queimaduras para determinar a progressão da doença para mitigar complicações como infecção e cicatrização. Sistemas de realidade aumentada poderiam permitir que profissionais treinados no reconhecimento de gravidade e profundidade da ferida triassem remotamente quais pacientes podem ser tratados localmente e quais devem ser encaminhados para unidades especializadas [Park et al., 2022].

Outras propostas que associam o uso da realidade aumentada com a triagem de pacientes estão relacionadas a grandes desastres. Nesse caso, o uso de sensores, óculos inteligentes e redes de comunicação permitiriam classificar, com a inserção de etiquetas virtuais, de forma mais rápida e eficaz as vítimas do desastre [Gillis et al., 2016, Nelson et al., 2022, Rae Nelson et al., 2022].

Nesse contexto, Nelson et al propõem o “*Augmented Reality Triage Tool Suite*” (ARTT), o qual é um software para auxiliar a triagem de vítimas, contendo uma ferramenta de triagem inicial, uma ferramenta de avaliação virtual e uma etiqueta de triagem virtual para ajudar os socorristas a lidar com o volume de vítimas. O software guia o atendimento, dando o passo a passo para triar os pacientes, marcando no sistema quais testes foram feitos e quais respostas foram obtidas. Na sequência, o software apresenta as principais medidas de resposta imediata, para guiar o socorrista e para registrar quais ações foram tomadas. Uma vez concluída a avaliação e assistência inicial, uma avaliação mais profunda é iniciada, por meio da interação entre diferentes profissionais. Para tanto, o sistema gera a etiqueta virtual do paciente, como mostrado na Figura 5.4. Ou seja, um socorrista pode estabilizar o paciente, enquanto outro recolhe o histórico e outro faz a movimentação do paciente para o hospital. A etiqueta virtual é uma abordagem mais eficiente que as etiquetas em papel, pois essas podem facilmente ser danificadas ou perdidas em um cenário de desastre. Além disso, a etiqueta de papel não pode ser atualizada pelos diferentes profissionais, enquanto que a digital permite isso [Rae Nelson et al., 2022].

5.3.1.3. Autotriagem (*Self-triage*)

A autotriagem ajuda pessoas a detectarem o nível de gravidade de sua doença, ajudando a decidir se devem ou não buscar atendimento em uma unidade de emergência. Os chatbots que não possuem apoio de profissionais de saúde são exemplos de aplicativos para autotriagem.

Durante a COVID-19, vários aplicativos foram desenvolvidos com perguntas e sugestões para ajudar na detecção e contenção da COVID-19. Esses aplicativos reduziram

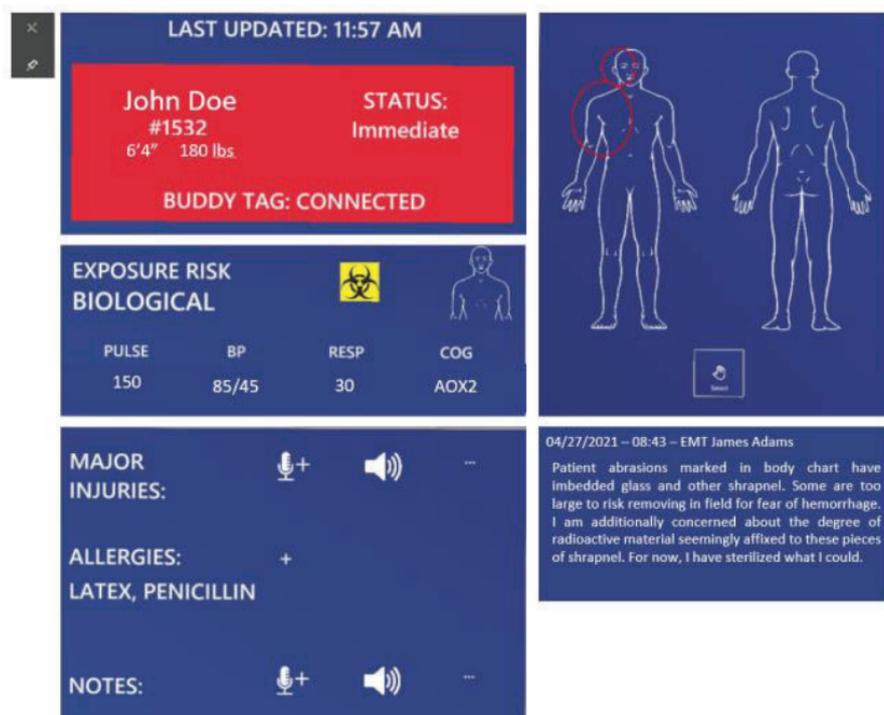


Figura 5.4. Etiqueta virtual do sistema de triagem com realidade aumentada ARTT. Fonte: [Rae Nelson et al., 2022].

os encaminhamentos desnecessários a hospitais por meio de várias perguntas, tais como informações gerais, localização geográfica, histórico recente de viagens, doenças subjacentes e sintomas. Algoritmos inteligentes são usados para determinar a condição do paciente, fornecendo sugestões de como proceder. Na maioria dos países, esses aplicativos de autoavaliação tiveram abrangência nacional, se tornando uma ferramenta essencial para triagem geral e detecção precoce de casos [Mastaneh e Mouseli, 2020, Ziebart et al., 2023]. Um exemplo de grande relevância foi o aplicativo chinês StarTimes ON, que foi utilizado por 45 países¹¹.

Outro exemplo para autotriagem é na detecção de problema de sono em idosos, com um aplicativo chamado de MotivSleep [Su et al., 2023]. O aplicativo faz perguntas sobre a qualidade do sono e encoraja o idoso a relatar comportamentos que podem afetar seu sono. Por fim, o MotivSleep gera recomendações personalizadas para com base nos comportamentos relatados.

5.3.1.4. Desafios da Teletriagem

Embora a teletriagem traga muitas facilidades, há que se considerar os aspectos técnicos e éticos com relação ao uso dessa técnica [Kobeissi e Ruppert, 2022]. Algumas considerações críticas se destacam, tais como uma avaliação da acuidade do paciente remoto, comparado ao atendimento presencial. A disponibilização de um aplicativo sem a devida avaliação por meio de um projeto de pesquisa sobre a sua efetividade consiste

¹¹<https://covid-19.chinadaily.com.cn/a/202003/30/WS5e8294a1a3101282172832ae.html>

em irresponsabilidade técnica, pois pode levar pacientes a tomarem ações que virão a prejudicar a sua saúde.

Outra questão de grande relevância é a definição de bons protocolos de triagem que possam ser digitalizados, para evitar a subestimação da gravidade de uma doença [Kobeissi e Ruppert, 2022]. Além disso, deve-se cuidar da segurança dos dados coletados.

5.3.1.5. Teletriagem de pacientes com diabetes

Um dos importantes projetos em andamento em Teletriagem iniciado pela *Madras Diabetic Research Foundation* (MDRF), Chennai, em colaboração com a *World Diabetes Foundation* (WDF), é o *MDRF/WDF Rural India Diabetes Prevention Project* [Prathiba e Rema, 2011]. Este programa da comunidade rural atende 42 aldeias (dentro e ao redor da aldeia de Chunampet) no distrito de Kancheepuram, Tamilnadu, Índia. A triagem é realizada no distrito de Chunampet para diabetes e suas complicações, especialmente doenças oculares diabéticas, usando uma van móvel de telemedicina com conectividade via satélite [Latifi et al., 2020, Choudhury et al., 2022]. A van de telemedicina está equipada com uma câmera digital da retina através da qual a imagem da retina é analisada por oftalmologistas. Todos os quadrantes da retina são visualizados pelo oftalmologista. Cerca de 2.000 pacientes com diabetes já foram submetidos à fotografia colorida da retina. Essas imagens são então transmitidas por meio de conectividade de satélite VSAT (*Very Small Aperture Terminal*) fornecida pela Organização de Pesquisa Espacial Indiana (ISRO) para o hospital de base em Chennai. Por videoconferência, o oftalmologista do hospital de base interage com os pacientes de áreas rurais e carentes. Os pacientes que precisam de tratamento adicional são levados a Chennai, onde a fotocoagulação a laser/cirurgia de catarata é realizada gratuitamente. Uma das principais vantagens da teleoftalmologia é a detecção precoce de alterações que ameaçam a visão e que podem ser tratadas. Os pacientes tratados servem como agentes da saúde para disseminar ainda mais as informações sobre os benefícios da teleoftalmologia para as aldeias vizinhas e também ajudar a remover crenças supersticiosas. A triagem para outras complicações relacionadas a diabetes, como nefropatia (medindo proteinúria/microalbuminúria), neuropatia (por biotesiometria e monofilamento) e doença arterial coronariana (por eletrocardiograma) também é feita na van de telemedicina.

5.3.1.6. Teletriagem de pacientes com deficiência visual

A *Retinopathy of prematurity* (ROP) causa deficiência visual, principalmente em países de baixa e média renda, em grande parte devido à falta de triagem [Young et al., 2023, Gilbert et al., 1997, Shah et al., 2016]. Um método eficiente para triagem nessas regiões de baixa e média renda é a telemedicina usando gradação remota de imagens de fundo digital de campo amplo (*Widefield Digital Fundus Imaging* - WDFI) [Young et al., 2023]. Esse método de telemedicina expande o alcance geográfico de especialistas. No entanto, uma barreira de implementação para programas de telemedicina em escala é o custo dessas câmeras. Muitos dos programas de telemedicina ROP existentes em países de baixa e média renda foram iniciados com investimento de capital externo de organizações

não-governamentais [Young et al., 2023, Gilbert et al., 1997]. Embora esses programas tenham fornecido evidências da eficácia dessa abordagem, ainda existem desafios de escalabilidade devido à quantidade de capital necessária para fornecer dispositivos WDFI a cada região necessitada. Assim, várias abordagens de baixo custo foram testadas, usando câmeras de dispositivos móveis ou sistemas de imagem de fundo de olho baseados em smartphone (SBFI) [Young et al., 2023].

Os sistemas SBFI funcionam combinando câmeras de smartphones modernas com lentes de oftalmoscopia indireta padrão para fornecer sistemas de imagem de fundo de olho acessíveis, portáteis e sem contato. Os sistemas SBFI são utilizados como complemento para oftalmoscopia indireta e documentação de ROP [Young et al., 2023, Gilbert et al., 1997, Shah et al., 2016]. No entanto, na maioria das vezes documentadas, o sistema tem sido utilizado por médicos treinados que, embora valioso para fins de documentação, isso anula o objetivo de expandir o alcance geográfico de um programa de telemedicina onde os médicos disponíveis são limitados. Além disso, todos os dispositivos de baixo custo fornecem um campo de visão mais estreito do que as câmeras WDFI padrão. A visualização da patologia periférica exige um clínico qualificado realizando a depressão escleral.

Trabalhos recentes usando a pontuação de gravidade vascular (*Vascular Severity Score* - VSS) derivada de inteligência artificial destacaram a associação entre a gravidade vascular no polo posterior e a presença e o grau de patologia periférica na ROP [Young et al., 2023, Gilbert et al., 1997, Shah et al., 2016]. Isso sugere que o baixo campo de visão dos sistemas de visualização de imagem podem fornecer imagens suficientes para a detecção de ROP grave se a gravidade vascular puder ser avaliada, seja por médicos ou por IA, mesmo que a patologia periférica não seja visualizada. Essa hipótese foi avaliada em [Young et al., 2023] comparando um dispositivo WDFI atualmente sendo implantado em um programa operacional de telemedicina, o Retcam Shuttle, com 2 dispositivos SBFI semelhantes, o adaptador Retcam feito na Índia e o oftalmoscópio indireto monocular Keeler. Ambos foram usados por técnicos para comparar o diagnóstico clínico obtido usando SBFI com WDFI e avaliar a eficácia do SBFI para detecção de encaminhamento garantido (RW)–ROP (definido como zona I, estágio 3 ou preplus) e que requer tratamento (TR)–ROP (ou seja, tipo I) e a precisão diagnóstica do VSS atribuído, além de avaliar se a IA pode ser útil para a classificação autônoma de imagens SBFI.

A Figura 5.5 mostra no topo esquerdo o sistema indiano Retcame e o oftalmoscópio indireto monocular. O Retcame mantém um smartphone e uma lente de oftalmoscopia indireta binocular padrão a uma distância fixa um do outro. A Figura 5.5 mostra no topo direito um exemplo de imagem de ROP em um estágio avançado obtida com o sistema Retcam. A Figura 5.5 mostra embaixo à esquerda que o oftalmoscópio indireto monocular Keeler prende um smartphone usando um suporte de cabeça. A lente é segurada pelo médico, semelhante ao oftalmoscópio indireto binocular tradicional. A Figura 5.5 mostra embaixo à direita um exemplo de imagem de ROP em um estágio avançado obtida com o sistema de câmera oftalmoscópio indireto monocular.



Figura 5.5. Sistema indiano para retinografia baseado em celulares. A Figura mostra a comparação entre as imagens geradas com equipamento médico e as geradas com o sistema proposto. Fonte: [Young et al., 2023].

5.3.2. Propostas para Teleconsulta e Teleinterconsulta

A teleconsulta, que permite uma consulta remota diretamente entre médico e paciente, só foi permitida no Brasil recentemente, devido à pressão do isolamento social causado pela COVID-19. Antes, era prevista a teleinterconsulta, na qual dois médicos poderiam interagir remotamente, visando o bem estar do paciente [Bertelli et al., 2022]. No caso da atenção básica, o teleatendimento é uma ferramenta importante para permitir o acesso à saúde, fazendo com que a promoção da saúde ocorra. Objetivamente, essa nova tecnologia de saúde aumenta o suporte à população, captura um maior conhecimento da comunidade assistida e, desta forma, dados importantes para uma melhor compreensão da população se tornam disponíveis, dando ensejo a novas e melhores abordagens ao local.

Não se pode deixar de lado o fato de que existem dilemas éticos presentes nesta modalidade de atendimento em rede, uma vez que essa consulta exigirá uma camada extra de cuidados com os dados do paciente que serão transmitidos por rede, a qual não poderá ficar vulnerável às interferências de pessoas mal intencionadas.

Assim, a teleconsulta e a teleinterconsulta são abordagens inovadoras no campo da telessaúde, permitindo tanto o atendimento remoto de pacientes quanto a discussão de casos entre profissionais em locais diferentes. As técnicas mais tradicionais utilizam sistemas de conferência por voz e/ou vídeo, embora sistemas de mensagem de texto também sejam utilizadas em alguns casos. Contudo, novas tecnologias estão surgindo para aperfeiçoar o teleatendimento, trazendo novas formas de visualização e de integração de dados à consulta. Esta seção visa apresentar os principais sistemas computacionais de atendimento, com foco nos sistemas de telepresença e sistemas multissensoriais de nova geração aplicados à saúde, assim como descrever os principais desafios tecnológicos associados.

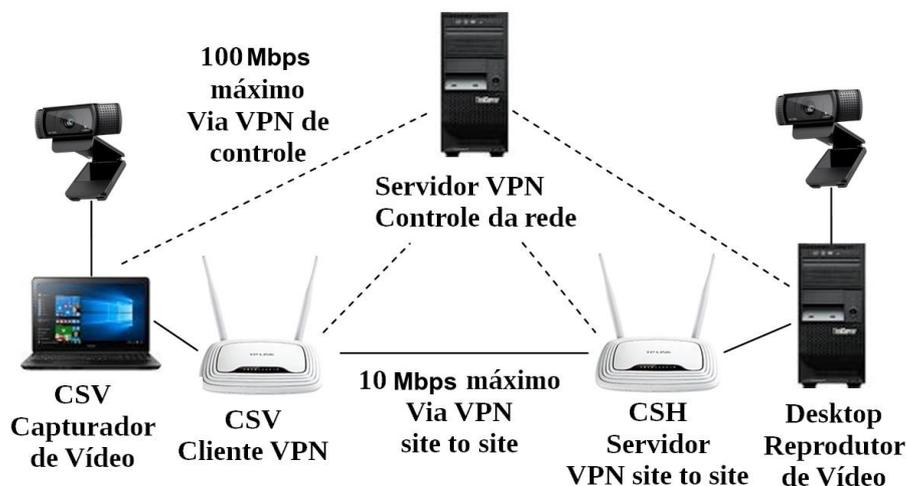
5.3.2.1. Uso de Imagens em 3D

Para algumas especialidades médicas, tais como as relacionadas à saúde mental e a geriatria, uma visão completa do paciente é necessária para uma boa avaliação do caso. A observação de mudanças de posição, tremores em partes específicas do corpo, entre outros, são sinais que fazem parte da anamnese do paciente. Nesse sentido, sistemas que só permitem comunicação por voz ou que permitam apenas a visualização do rosto do paciente não são adequados para esse tipo de teleatendimento. Sistemas de telepresença que permitam a visualização global do paciente se tornam muito importantes nesse contexto [Boechat et al., 2017, Beaklini et al., 2017].

Dentre as iniciativas para criação de um ambiente de telepresença, destaca-se o projeto de Telessaúde por Holografia da Universidade Federal Fluminense, que proporciona uma experiência imersiva na teleinterconsulta usando a técnica Pepper's Ghost para gerar a sensação de 3D nas imagens, trazendo o consultório remoto completo para perto do médico especialista. O projeto Telessaúde por Holografia conta com um sistema em software desenvolvido sobre a plataforma Linux, que é capaz de estabelecer conexões ponto a ponto privadas, sem passagem de dados por servidores ou pela nuvem, garantindo a segurança dos dados dos pacientes [Fonseca et al., 2018]. O sistema também realiza o controle automático das taxas de codificação, uma vez que foi desenvolvido para dar suporte ao atendimento remoto de populações ribeirinhas da Amazônia, aonde o acesso à Internet é precário. A Figura 5.6 mostra a arquitetura do sistema e um exemplo da imagem holográfica. O sistema foi utilizado para atender centenas de pacientes na Amazônia, em uma parceria entre a UFF e o Exército Brasileiro, e, atualmente, é parte do Núcleo de Telessaúde da UFF, para o teleatendimento da população do Rio de Janeiro, em uma parceria entre a UFF e a Secretaria de Saúde de Niterói.

5.3.2.2. Teleatendimento com realidade aumentada e metaverso

O avanço das tecnologias para criação de metaverso, que são universos online interconectados, com o avanço das técnicas de realidade aumentada, traz uma nova gama de possibilidades de experiências imersivas em tempo real. Essas tecnologias também vem sendo propostas dentro do campo da saúde, considerando questões como a interoperabilidade com configurações clínicas virtuais do mundo real, facilidade de uso das



(a) Equipamentos de baixo custo utilizados no Sistema de Telessaúde Holográfico.



(b) Fotos da visualização da holografia no CSH.

Figura 5.6. Imagens do Sistema de Telessaúde Holográfico da UFF, no qual os consultórios são chamados de Centro de Saúde Virtual (CSV) e o centro de projeção holográfica, aonde ficam os médicos especialistas, é chamado de Centro de Saúde Holográfico (CSH).

tecnologias e sua eficiência clínica, questões econômicas, regulamentares e padrões de segurança cibernética [Tan et al., 2022].

Alguns estudos focam na aplicação da Realidade Aumentada na saúde mental. Isso se deve porque a detecção de problemas de saúde mental durante consultas pode ser desafiadora em alguns casos. Essa avaliação psiquiátrica e o tratamento de transtornos depressivos podem ser melhorados usando biomarcadores comportamentais e fisiológicos objetivos.

Ramalho et al desenvolveram uma plataforma de telemedicina psiquiátrica capaz de analisar dois biomarcadores importantes de depressão, a frequência de piscar de olhos

e a variabilidade da frequência cardíaca. O sistema captura em tempo real o fluxo de vídeo da teleconsulta e computa o número de vezes que o paciente piscou. Além disso, o sistema também computa em tempo real a variabilidade da frequência cardíaca por meio de uma técnica chamada de fotopletiografia remota (*remote Photoplethysmography - rPPG*). Essa técnica se baseia nos dados do rosto, que contém um sinal suficientemente rico para medir a frequência cardíaca sob luz ambiente, usando apenas uma câmera digital e processamento de sinal. Os dois biomarcadores são mostrados em tempo real, durante a consulta, para o médico, para que ele possa ter uma melhor avaliação da condição do paciente [Ramalho et al., 2022].

Outros trabalhos citam o uso da realidade virtual e do metaverso em diversas especialidades, com foco nas teleinterconsultas cirúrgicas. O uso de *smart glasses* e óculos de realidade virtual vem sendo cada vez mais discutidos nos atendimentos síncronos em saúde. Além disso, alguns trabalhos chegam a citar o uso de avatares, que são modelos humanos em 3D controlados por um usuário, no atendimento remoto [Palumbo, 2022].

Outro estudo demonstra um protótipo, aonde um profissional de saúde pode dar instruções sobre como lidar com um paciente para outro profissional de saúde. O protótipo é demonstrado com um manequim, como mostrado na Figura 5.7, aonde o profissional remoto é plotado para o profissional local, mostrando como deve ser feito o movimento e deixando marcas virtuais que serão usadas pelo profissional local para repetir o movimento [Dinh et al., 2023].

5.3.2.3. Uso de robôs na teleconsulta

A realização de consultas e procedimentos com robôs teleguiados é outra tendência para os próximos anos, em especial no tratamento de doenças contagiosas. Dentro desse contexto, algumas iniciativas surgiram durante a pandemia de COVID-19.

Uma dessas iniciativas foi o desenvolvimento de um robô teleguiado para realizar ultrassonografia de pulmão em 2D [Tsumura et al., 2021], que é um exame que ajuda na detecção rápida da COVID-19. Outra iniciativa foi no uso de robôs para medir sinais vitais, fazer testes laboratoriais, limpar e desinfetar hospitais, entregar medicamentos e comida para pacientes, entre outros, em alas de pacientes com COVID-19. O estudo chega a sugerir o uso de robôs para interações sociais, melhorando o estado do paciente em situações de isolamento [Mastaneh e Mouseli, 2020].

5.3.3. Telediagnóstico

O telediagnóstico é uma modalidade de teleatendimento que utiliza tecnologias de informação e comunicação (TIC) para realizar diagnósticos à distância. Essa prática é especialmente importante para melhorar o acesso a serviços médicos especializados em áreas remotas ou com poucos recursos [Conselho Federal de Medicina, 2022]. Além disso, essa modalidade de teleatendimento corrobora no auxílio do diagnóstico precoce, no tratamento de doenças, na redução dos custos da saúde e no aumento da qualidade de vida e satisfação dos pacientes, uma vez que a necessidade de deslocamento se reduz.

Nesse contexto, o telediagnóstico é caracterizado como o diagnóstico realizado a



Figura 5.7. Protótipo de sistema de teleinterconsulta utilizando realidade virtual e realidade aumentada. Fonte: [Dinh et al., 2023].

partir de uma separação física entre o médico e o paciente. Ele pressupõe o acesso remoto aos resultados de testes e registros médicos do paciente, eliminando a necessidade de um contato físico real entre as partes durante o exame [Qazi et al., 2019]. Esse procedimento pode ser realizado por meio de diferentes estratégias de comunicação, incluindo discussões por videoconferência e mensagens instantâneas. Nos últimos anos, foram desenvolvidas diversas propostas para aprimorar o telediagnóstico e duas delas merecem destaque:

- **Interpretação de exames médicos:** O telediagnóstico abrange a interpretação de exames médicos, permitindo que médicos e especialistas analisem imagens e resultados de testes à distância. Essa abordagem facilita o acesso a informações diagnósticas cruciais, como radiografias, tomografias e ressonâncias magnéticas, possibilitando uma avaliação minuciosa e precisa.
- **Análise de dados clínicos e tomada de decisão:** Além da interpretação de exames, o telediagnóstico envolve a análise de dados clínicos do paciente, incluindo histórico

médico, resultados de testes laboratoriais e outras informações relevantes. Com base nessas informações, os médicos podem tomar decisões clínicas à distância, prescrever tratamentos adequados e fornecer orientações personalizadas.

O uso dessa modalidade de teleatendimento permite que médicos e especialistas realizem suas atividades de análise e tomada de decisão remotamente, superando barreiras geográficas e temporais. Ao utilizar tecnologias de comunicação, é possível compartilhar resultados de exames e emitir pareceres ou laudos especializados, o que contribui para uma abordagem mais integrada e eficiente à saúde.

A aplicação dos serviços de telediagnóstico tem demonstrado uma série de vantagens significativas, que não apenas impactam positivamente os pacientes, mas também contribuem para a eficiência e eficácia do sistema de saúde como um todo. Algumas das principais vantagens estão descritas a seguir:

1. Acesso ampliado a serviços médicos especializados: O telediagnóstico permite superar barreiras geográficas e melhorar o acesso a serviços médicos especializados, especialmente em áreas remotas e carentes de recursos. Por meio dessa abordagem, pacientes podem receber diagnósticos e orientações de profissionais altamente qualificados, mesmo estando distantes fisicamente;
2. Diagnóstico mais rápido e tratamento oportuno: Através do telediagnóstico, é possível obter diagnósticos mais rápidos e precisos, o que resulta em tratamento oportuno e eficaz. A transmissão de dados clínicos, exames e imagens em tempo real permite uma análise imediata por especialistas, reduzindo o tempo de espera e minimizando a progressão de doenças;
3. Redução de custos e deslocamentos desnecessários: O telediagnóstico elimina a necessidade de deslocamentos frequentes dos pacientes para consultas médicas presenciais. Isso resulta em economia de tempo e recursos financeiros, tanto para os pacientes quanto para o sistema de saúde. Além disso, os custos associados a viagens e estadias hospitalares podem ser reduzidos, contribuindo para a sustentabilidade econômica do sistema de saúde;
4. Melhoria na qualidade de vida dos pacientes: O telediagnóstico oferece conveniência e comodidade aos pacientes, permitindo que recebam cuidados médicos no conforto de seus lares. Isso reduz o estresse e o desconforto associados a deslocamentos e longas esperas em hospitais, proporcionando uma melhor qualidade de vida. Além disso, o acesso facilitado a especialistas possibilita uma abordagem mais abrangente e personalizada, melhorando a experiência do paciente.

Essas vantagens do telediagnóstico têm sido comprovadas em uma série de estudos científicos. Por exemplo, o estudo conduzido por H. Peter Soyer (2020), Vestergaard e Wulf demonstraram uma vantagem significativa do uso de equipamentos digitais no telediagnóstico. Nesse estudo, os pesquisadores avaliaram a precisão da teledermatoscopia digital móvel para o autoexame de pele em adultos com alto risco de câncer de pele. Os participantes utilizaram um dispositivo móvel equipado com um aplicativo de

tele dermatologia para capturar imagens de lesões de pele e enviá-las para análise remota por dermatologistas [Vestergaard e Wulf, 2020]. Os resultados revelaram que a tele dermatoscopia digital móvel apresentou uma alta precisão na detecção de lesões suspeitas de câncer de pele, com uma taxa de concordância significativa entre os diagnósticos realizados pelos dermatologistas presenciais e os dermatologistas remotos. Isso significa que o uso do telediagnóstico, por meio da tele dermatoscopia digital móvel, pode oferecer uma ferramenta eficaz para o autoexame de pele em pacientes de alto risco.

Pagano et al investigaram a colaboração entre enfermeiras e oftalmologistas em um país de renda média, visando expandir o acesso aos cuidados com os olhos [Pagano et al., 2021]. O estudo validou a aquisição de dados de saúde por meio de enfermeiras em uma estratégia de telemedicina. Essa abordagem permitiu que pacientes em áreas rurais tivessem acesso a exames oftalmológicos, mesmo sem a presença física de um oftalmologista. Os resultados mostraram que a parceria entre enfermeiras e oftalmologistas por meio do telediagnóstico foi eficaz na ampliação do alcance dos cuidados com os olhos, proporcionando diagnósticos precoces e intervenções adequadas. Isso demonstra claramente a vantagem do uso do telediagnóstico em áreas rurais, onde o acesso a especialistas é limitado [Pagano et al., 2021].

Outra vantagem é a utilização de tecnologias avançadas, como inteligência artificial (IA) e aprendizado de máquina, que podem aprimorar a interpretação de exames médicos e análise de dados clínicos. O uso de algoritmos e modelos de IA podem aumentar a precisão e rapidez das análises médicas, contribuindo para diagnósticos mais precisos e eficientes.

No entanto, é importante mencionar que o avanço do telediagnóstico também traz desafios a serem superados. Um dos principais é a necessidade de infraestrutura tecnológica adequada, como conexão estável à Internet e equipamentos de transmissão de dados. Além disso, é essencial garantir a segurança e privacidade das informações transmitidas, protegendo os dados dos pacientes contra possíveis violações na era digital.

Para seguir o procedimento ético padrão, os dados médicos e informações pessoais recebidos dos pacientes são compartilhados de forma voluntária ao profissional de saúde que, infelizmente, podem ser capturadas por meios ilícitos ou por meio de autorizações especiais [Ruaro e Rodriguez, 2017]. Neste contexto, a coleta massiva de informações pessoais ameaça a privacidade dos pacientes, levantando preocupações sobre exposição indesejada e violações de privacidade. Ademais, a segurança cibernética se tornou um desafio constante, exigindo também que as instituições de saúde implementem medidas robustas para proteger dados pessoais contra hackers e violações. Este desafio se estende ao Estado, uma vez que a falta de regulamentação adequada e a inconsistência nas leis de proteção de dados também dificultam a aplicação efetiva das medidas de proteção. Esses desafios destacam a necessidade de abordagens atualizadas e abrangentes para garantir a confidencialidade das informações transmitidas e proteger adequadamente os dados pessoais.

5.3.3.1. Desafios na transmissão de dados de grande volume

Um dos grandes desafios do telediagnóstico para alguns exames de imagem é a dificuldade de envio de grandes volumes de dados pela Internet. Esse problema se observa, por exemplo, na realização de teleultrassom.

O monitoramento por teleultrassom vem sendo utilizado para monitoramento de pulmão, tireóide e fígado, no qual os vídeos de ultrassom adquiridos de forma assíncrona seguindo o protocolo de varredura de volume são enviados pela rede. Nessa técnica, uma das principais limitações é a baixa largura de banda nas localidades aonde as imagens são coletadas. Para reduzir esse problema, Romero et al propuseram uma técnica de reconstrução que permite que, a partir do envio de uma única imagem que inclua todas as informações da aquisição por meio da reconstrução panorâmica do vídeo ultrassonográfico, possa se recuperar os dados necessários para a análise remota. Para essa técnica, utiliza-se um fantoma de ultrassom com o *scanner* de ultrassom disponível comercialmente com um transdutor linear em diferentes profundidades de aquisição. A reconstrução da imagem no destino é um processo em três fases, que incluem a detecção do momento de aquisição, por meio de fluxo óptico; o processamento de imagem para seleção da região de interesse e ajuste de intensidade; e a reconstrução panorâmica determinando o deslocamento entre quadros. A técnica é mais bem sucedida para imagens mais profundas e de maior contraste [Romero et al., 2023].

5.3.3.2. Aplicação de novas tecnologias no telediagnóstico

A aplicação de aprendizado de máquina no suporte ao telediagnóstico tem sido um ponto forte nas pesquisas recentes. O potencial transformador dessa ferramenta no telediagnóstico é significativo. A Figura 5.8 mostra como o aprendizado de máquina, ao ser implementado em plataformas de telediagnóstico, pode oferecer suporte aos profissionais de saúde em diferentes cenários. Primeiramente, essa ferramenta pode ser utilizada para uma reavaliação de laudos de exames prévios, aumentando a confiabilidade dos diagnósticos. Isso é particularmente útil em situações em que o acesso a especialistas é limitado, permitindo que médicos generalistas ou especialistas em outras áreas tenham uma segunda opinião automatizada e precisa.

A implementação dessas ferramentas no telediagnóstico também pode levar a uma maior eficiência nos serviços de saúde do SUS, especialmente em regiões com recursos limitados. Isso contribui para democratizar o acesso a diagnósticos mais precisos e melhorar a qualidade dos serviços de saúde em geral.

Entre os exemplos da aplicação de aprendizado de máquina para o telediagnóstico, tem-se o trabalho de De Souza Filho et al, que propõe uma ferramenta baseada em algoritmos de Aprendizado de Máquina para distinguir mapas polares de perfusão miocárdica normais de mapas anormais em imagens de SPECT (Tomografia Computadorizada por Emissão de Fóton Único - *Single-Photon Emission Computed Tomography*) do miocárdio [de Souza Filho et al., 2021]. O estudo implementou com sucesso quatro algoritmos de aprendizado de máquina - *Random Forest* (RF), *Gradient Boosting* (GB), *XGBoost* (XGB) e *AdaBoost* (AB), para realizar a tarefa de classificação dos mapas polares. Fo-



Figura 5.8. Fluxograma de algoritmos de aprendizado de máquina para auxiliar decisões médicas.

ram utilizados 10 atributos diferentes, extraídos por meio de um processo de fatiamento de imagem e utilizando a técnica de validação cruzada para avaliar o desempenho dos algoritmos. O resultado dessa pesquisa indica que a ferramenta desenvolvida utilizando algoritmos de aprendizado de máquina foi capaz de distinguir com sucesso mapas polares de perfusão miocárdica normais e anormais. Além disso, o estudo também aponta que o algoritmo *Random Forest* obteve o melhor desempenho, medido pelo indicador AUC (Área Sob a Curva ROC - *Area Under the ROC Curve*).

Özbilgin et al utilizaram técnicas de aprendizado de máquina para desenvolver em telediagnóstico previsão de doença arterial coronariana a partir da análise de íris. A doença arterial coronariana (*Coronary Artery Disease - DAC*) ocorre quando os vasos coronários se endurecem e se estreitam, limitando o fluxo sanguíneo para os músculos cardíacos e tem uma alta taxa de mortalidade. Portanto, o diagnóstico precoce da DAC pode prevenir a progressão da doença e facilitar o tratamento. Os autores desenvolveram um modelo usando transformada de wavelet, análise estatística de primeira ordem, uma matriz de co-ocorrência de nível de cinza, uma matriz de extensão de execução de nível de cinza e *Support Vector Machine (SVM)*, que usa imagens da íris para diagnosticar a DAC. O modelo apresentou uma taxa de precisão de 93% para prever DAC, mostrando que essa modalidade de telediagnóstico consegue diagnosticar preliminarmente a doença arterial coronariana sem a necessidade de eletrocardiografia, ecocardiografia e testes de esforço. Pela facilidade de obtenção das imagens e de aplicação do modelo online, a técnica é facilmente aplicável em sistemas integrados de telemedicina [Özbilgin et al., 2023].

5.3.4. Propostas para Telemonitoramento

O telemonitoramento, também conhecido como monitoramento remoto do paciente, é um serviço de saúde baseado em tecnologia que permite aos profissionais de saúde monitorar e gerenciar remotamente as condições de saúde dos pacientes usando vários dispositivos, sensores e ferramentas de comunicação [Scalvini et al., 2004, Latifi et al., 2020, Choudhury et al., 2022]. O telemonitoramento tornou-se uma abordagem cada vez mais popular para a prestação de cuidados de saúde, especialmente durante a pandemia do COVID-19, pois permite que os pacientes recebam atendimento no conforto de suas próprias casas, reduzindo o risco de exposição ao vírus. O monitoramento contínuo da saúde do paciente oferece um melhor conhecimento de sua condição e permite um melhor fluxo de informações para supervisão, tratamento e recuperação [Soto et al., 2022b, Ferreira et al., 2018, Santos et al., 2020a].

Uma proposta de telemonitoramento para cuidados de saúde envolve a implementação de um sistema de monitoramento remoto de pacientes que permita aos profissionais de saúde monitorar os sinais vitais dos pacientes, como pressão arterial, frequência cardíaca e níveis de oxigênio, em tempo real [Darkins et al., 2008, Fahmy, 2020]. Usualmente, programas de telemonitoramento visam pacientes com condições crônicas, como hipertensão, insuficiência cardíaca e diabetes, que requerem monitoramento regular de seus sinais vitais, ou pacientes internados em hospitais [Debnath et al., 2023]. O programa deve usar dispositivos aprovados pelas autoridades, que sejam confiáveis, precisos e fáceis de usar. Esses dispositivos podem incluir monitores de pressão arterial, oxímetros de pulso, glicosímetros, etc [Scalvini et al., 2004].

Existem ainda sistemas de telemonitoramento que são baseados em entradas dos pacientes em aplicativos de celular. Por exemplo, os aplicativos para acompanhamento de mulheres com gravidez de risco, desenvolvidos por Cuervas et al [Robles Cuevas et al., 2022]. Nesse sistema, existe um aplicativo para as grávidas, no qual elas podem entrar com sintomas que estão sentindo, e um aplicativo para profissionais de saúde, no qual se observa dados históricos e alarmes gerados automaticamente sobre as condições relatadas pelas gestantes.

Outros sistemas interagem com equipamentos na casa do paciente. Por exemplo, o sistema para telemonitoramento do avanço de ascite cirrótica, proposto por Bloom et al, permite telemonitorar a ascite pelo peso do paciente. Nesse caso, o sistema coleta automaticamente os valores obtidos por balanças inteligentes na casa do usuário. A análise do sistema, mostrado na Figura 5.9, identificou que, com o sistema, pode-se reduzir o custo do tratamento para 100 pacientes com ascite cirrótica, em um período de 6 meses, em U\$167.500,00 [Bloom et al., 2022].

Quando o telemonitoramento é feito fora de ambientes hospitalares, os pacientes devem receber treinamento e suporte para garantir que se sintam confortáveis usando os dispositivos e ferramentas de comunicação. Isso pode incluir vídeos instrutivos, manuais do usuário e suporte técnico. O programa deve ter um sistema para monitorar os sinais vitais dos pacientes em tempo real e gerar alertas se alguma leitura estiver fora dos intervalos normais. Os profissionais de saúde devem poder acessar essas informações por meio de um portal da Web seguro ou aplicativo móvel [Choudhury et al., 2022].

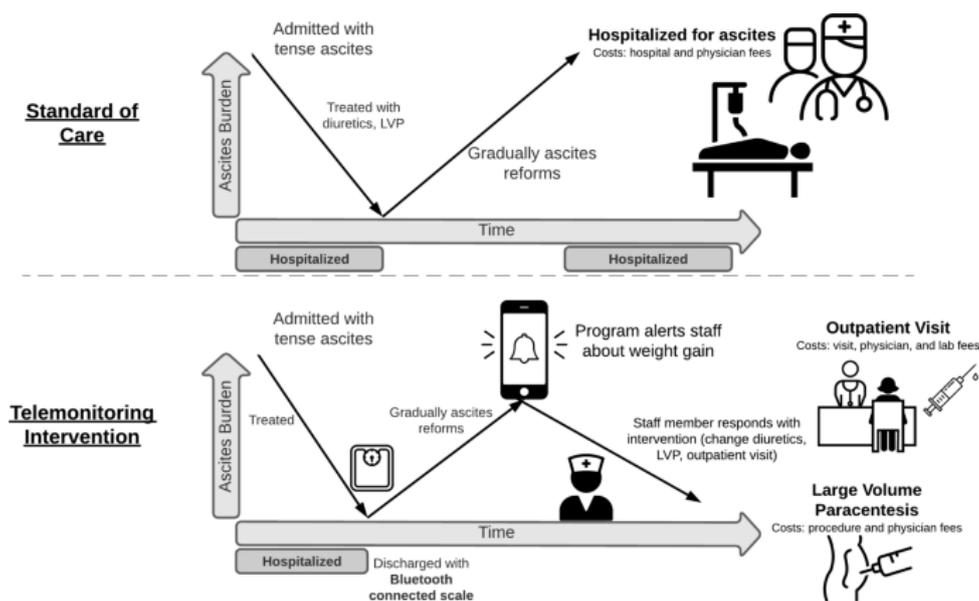


Figura 5.9. Sistema para detecção precoce de ascite cirrótica, por meio de um aplicativo no telefone celular e balanças inteligentes na casa dos pacientes.
 Fonte: [Bloom et al., 2022].

Uma referência para uma proposta bem-sucedida de telemonitoramento é um estudo realizado pelo sistema de saúde *Veterans Affairs* (VA) nos Estados Unidos [Darkins et al., 2008]. O estudo mostrou que o telemonitoramento melhorou os resultados dos pacientes, reduziu as hospitalizações e reduziu os custos de saúde para pacientes com condições crônicas, como hipertensão, insuficiência cardíaca e diabetes. O programa de telemonitoramento do VA incluiu o uso de dispositivos de monitoramento doméstico, mensagens seguras e visitas virtuais com profissionais de saúde. O programa resultou em uma redução de 19% nas hospitalizações e uma redução de 25% nos leitos de cuidados, levando a uma economia de custos de US\$ 1.600 por paciente por ano. A proposta envolve o processo de encaminhamento, seleção de pacientes, dispositivos de monitoramento, ferramentas de comunicação, coordenação de cuidados e cuidados de acompanhamento [Darkins et al., 2008, Fahmy, 2020]. Esses conceitos são cruciais para garantir que os pacientes recebam os cuidados e suporte adequados ao usar os serviços de monitoramento remoto.

5.3.4.1. Novas tecnologias aplicadas ao telemonitoramento

Dispositivos portáteis de saúde estão entre os de crescimento mais rápido no mercado da Internet das Coisas (IoT). Com o avanço da IoT, esses dispositivos móveis ganharam impulso no domínio das aplicações digitais biomédicas e de saúde, levando a aplicações de saúde de nova geração. A seguir, são apresentadas algumas soluções tecnológicas disruptivas em telemonitoramento.

Telemonitoramento de pacientes com diabetes utilizando aprendizado de máquina

O acompanhamento da diabetes por telemonitoramento é um foco de pesquisa

da última década. Nos últimos 5 anos, surgiram projetos de nova geração que suportam sensores (implantados ou vestíveis, dependendo do projeto) com transmissão automática dos dados por Wi-Fi ou *Bluetooth* e interpretação remota dos dados dos pacientes para acompanhamento e intervenções preventivas. Vários desses projetos usam aprendizado de máquina para realizar ações automáticas, como ajuste do nível de glicemia à atividade do paciente, usando softwares como o DiabeoTM [Charpentier et al., 2011], e prever risco de descompensação do diabetes, com softwares como o MyPredTM [Andrès et al., 2018]. Um dado interessante é que, no tratamento do diabetes, os dispositivos implantáveis de telemonitoramento para múltiplos parâmetros já se provaram como uma abordagem eficaz [Andrès et al., 2019].

Acompanhamento remoto de idosos para detecção de quedas

Existem várias abordagens para monitorar a atividade humana que podem ser empregadas para detectar quando ocorreu um evento de queda. Os sistemas de detecção de eventos baseados no monitoramento de atividades foram desenvolvidos usando diferentes técnicas de detecção [Colón et al., 2014]. Nesse sentido, alguns sistemas usam sensores de *smartphones* como acelerômetros, giroscópios e magnetômetros ou sensores vestíveis para detectar quando a queda aconteceu [Colón et al., 2014], enquanto que outros sistemas são baseados na detecção automática com imagens de câmeras [Cardenas et al., 2020].

Sistemas de detecção de queda vem ganhando importância para o suporte no acompanhamento de idosos. De fato, grandes melhorias na expectativa de vida têm sido a tendência predominante para os países desenvolvidos e de alta renda ao longo dos séculos XX e XXI [Ho e Hendi, 2018]. O aumento global da expectativa de vida humana criou a necessidade de tecnologia de saúde e monitoramento remoto adequado para idosos e um dos maiores problemas de saúde dos idosos são as quedas que ocorrem em casa durante as Atividades da Vida Diária (AVD) [Cardenas et al., 2020]. Mesmo em asilos, com atendimento contínuo, a incidência de quedas é estimada em 13,1% [Quigley et al., 2012]. Em ambos os casos, o tempo até a detecção da queda e o socorro do idoso por responsáveis é determinante para controlar as consequências do acidente e, algumas vezes, para evitar até o falecimento do idoso.

As abordagens baseadas em celulares ou sensores vestíveis costumam ser de implantação desafiadora com idosos, porque eles esquecem de portar o sensor a todo o tempo e usualmente tem dificuldades para lidar e aceitar novas tecnologias. Os sistemas baseados em vídeo acabam sendo uma solução mais simples para ambientes fechados e controlados. Contudo, esses sistemas baseados em vídeo têm limitações na detecção de quedas devido a mudanças no fundo da imagem, objetos de fundo, iluminação e movimento da câmera [Mehta et al., 2021]. Algumas abordagens não funcionam em ambientes pouco iluminados, por exemplo, quando o idoso está no quarto à noite e precisa se levantar para ir ao banheiro ou tomar remédios. Outro problema relevante é que muitos desses algoritmos não são adequados para detectar quedas usando câmeras infravermelhas, podendo não funcionar em ambientes escuros [Hernandez et al., 2014].

Xu et al desenvolveram uma CNN para detecção de queda através da formação de um mapa 2D do corpo ósseo do sujeito identificado nas gravações de câmeras RGB. Eles usaram OPENPOSE para converter a imagem na imagem do esqueleto correspondente. Em seguida, usando aprendizado de transferência, o conjunto de dados foi usado para

treinar um novo modelo de detecção de queda [Xu et al., 2020]. A partir da imagem colorida, o OPENPOSE pode usar o modelo MobileNet para obter a imagem do esqueleto 2D, conforme mostrado na Figura 5.10.

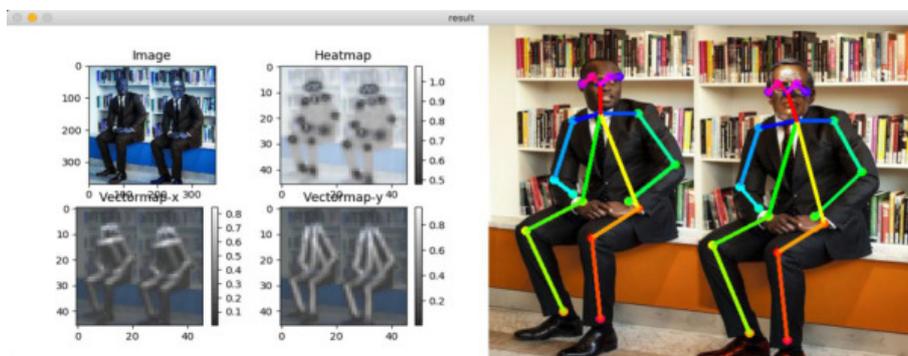


Figura 5.10. Imagem em tons de cinza, mapa de calor, mapa ósseo obtido a partir da imagem HD. Fonte: [Xu et al., 2020]

Mehta et al propuseram o 3D *Convolutional Autoencoder* (3DCAE) para detecção de eventos anormais aplicado à detecção de quedas. A estrutura proposta com aprendizagem adversária generativa usa movimento e definição de região de interesse para detectar quedas com imagens térmicas. O modelo consiste em uma rede de dois canais, com um canal aprendendo explicitamente o movimento na forma de um fluxo óptico, enquanto o outro recebe quadros de vídeo brutos como entrada. A abordagem pode lidar com situações em que uma pessoa pode não estar presente em um quadro, reduzindo a taxa de falsos positivos [Mehta et al., 2021]. A Figura 5.11 mostra que o sistema proposto por Mehta et al para detecção de quedas com câmeras termais reconhece a região da imagem onde a pessoa está presente e o contorno desta pessoa para cada *frame* da câmera termal.

Santos et al estenderam o 3DCAE para ser utilizado com câmeras RGB e infravermelho, visando o uso do sistema em asilos [Santos et al., 2022]. Nesse modelo, Santos et al propõem e avaliam um modelo de pré-processamento para melhorar a detecção pelo algoritmo de redes neurais. Diferente de outras propostas da literatura, o modelo detecta quedas em ambientes com alta iluminação com câmeras RGB ou mesmo sem iluminação com câmeras com IR. Assim, o sistema utiliza estrategicamente as câmeras domésticas em áreas onde os idosos com mobilidade reduzida apresentam maior risco de queda. Este sistema ajuda a aumentar a independência e, conseqüentemente, a auto-estima do usuário.

Telemonitoramento com Wi-Fi

Técnicas não invasivas e ubíquas para o monitoramento de pessoas são de grande interesse, já que podem promover a saúde sem causar desconfortos. Entre essas tecnologias que visam esse fim, destaca-se a iniciativa recente do uso de *Channel State Information* (CSI) de redes *Wi-Fi* para monitorar pacientes remotamente, podendo fornecer meios para obter um poderoso pacote de informações médicas de forma não invasiva e com baixo custo [Soto et al., 2022b].

O sinal CSI representa a resposta em frequência do canal (*Channel Frequency Response* - CFR) para cada subportadora entre os pares de antenas de transmissão e recepção [Soto et al., 2022a]. O CSI pode capturar as interferências que o corpo humano



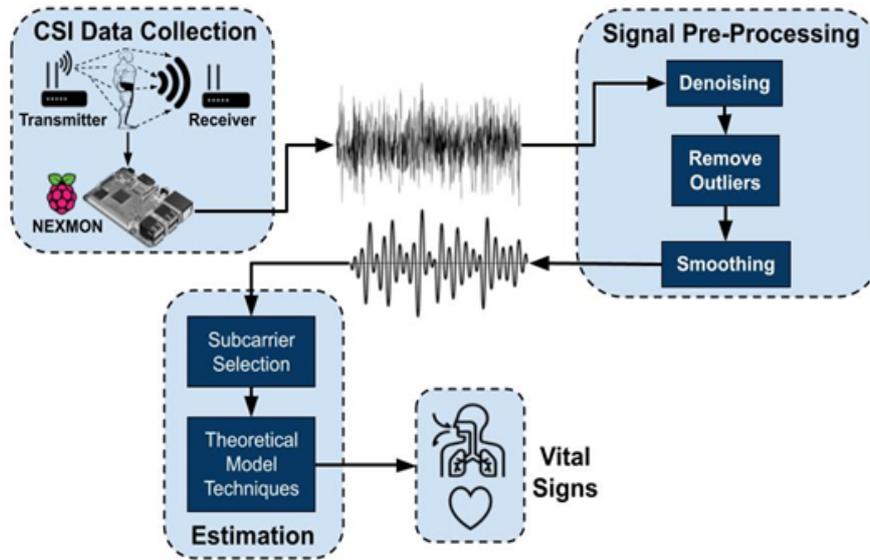
Figura 5.11. Tratamento das imagens para detecção de quedas com câmeras termais usando o 3DCAE. Fonte: [Mehta et al., 2021].

causa no sinal eletromagnético nos domínios do tempo e da frequência e em domínios espaciais. Essas informações podem ser usadas para diferentes aplicações, como a detecção da presença humana, detecção de movimentos, identificação humana, detecção de queda, reconhecimento de gestos, localização humana e monitoramento de sinais vitais e das condições de saúde [Soto et al., 2022b, Soto et al., 2022a]. Para monitoramento das condições de saúde, as subportadoras do OFDM (*Orthogonal Frequency Division Multiplexing*) são usadas como vários sensores para detectar a mudança física de uma pessoa. Uma análise de forma de onda CSI permite detectar atividades mínimas do corpo humano, como a respiração, os batimentos cardíacos, dentre outros.

Soto et al, em uma pesquisa nacional desenvolvida no Laboratório MídiaCom da Universidade Federal Fluminense, estão desenvolvendo um sistema baseado em CSI para detecção de sinais vitais de pessoas em ambientes fechados. Utilizando um Raspberry Pi e dois equipamentos de uso comum com Wi-Fi, como um ponto de acesso e um computador, conforme mostrado na Figura 5.12(a), os pesquisadores conseguiram obter taxas precisas para batimento cardíaco e taxa respiratória em experimentos realizados no ambiente mostrado nas Figuras 5.12(b) e 5.12(c). A tecnologia, por sua simplicidade, baixo custo e resultados no monitoramento de saúde não invasivo, tem grandes potenciais para a criação de ferramentas de telemonitoramento, sendo um alvo interessante para pesquisas nos próximos anos.

Telemonitoramento com sensores implantados

Sensores implantados também vêm sendo alvos de pesquisas em telemonitoramento. Por exemplo, durante a pandemia, foram iniciados alguns estudos com sensores implantados conectados em rede para facilitar a identificação precoce de casos de COVID-



(a) Arquitetura empregada nos testes do CSI.



(b) Ambiente de testes.



(c) Execução dos testes.

Figura 5.12. Projeto CSI UFF, para detecção de sinais vitais de forma não invasiva, utilizando equipamentos de uso diário com Wi-Fi.

19 [Bai et al., 2020]. Um exemplo bem-sucedido aconteceu em Hong Kong, onde os sensores remotos conectados à Internet foram incorporados no braço dos indivíduos, examinando sinais vitais e níveis de oxigênio no sangue e enviando-os para uma plataforma digital para monitoramento e análise em tempo real¹². Pesquisadores da Universidade de Hong Kong (HKU) e uma start-up de tecnologia de saúde com sede em Boston uniram forças para iniciar um programa para rastrear os indicadores de saúde de 50 pacientes e

¹²<https://opengovasia.com/hk-researchers-and-us-tech-start-up-partner-to-help-solve-covid-19-virus/>

150 pessoas sob ordens de quarentena. Os participantes voluntários usaram um dispositivo com sensores implantados na parte superior do braço 24 horas por dia, por meio do qual dados como temperatura corporal, frequência respiratória, nível de oxigênio no sangue e frequência cardíaca foram enviados a uma plataforma digital para monitoramento em tempo real e análise.

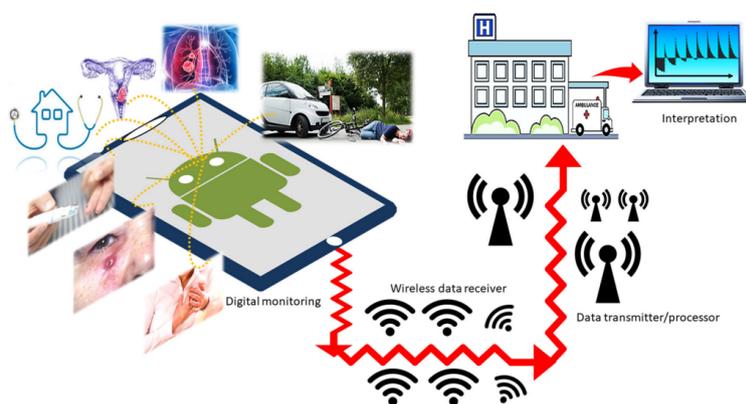
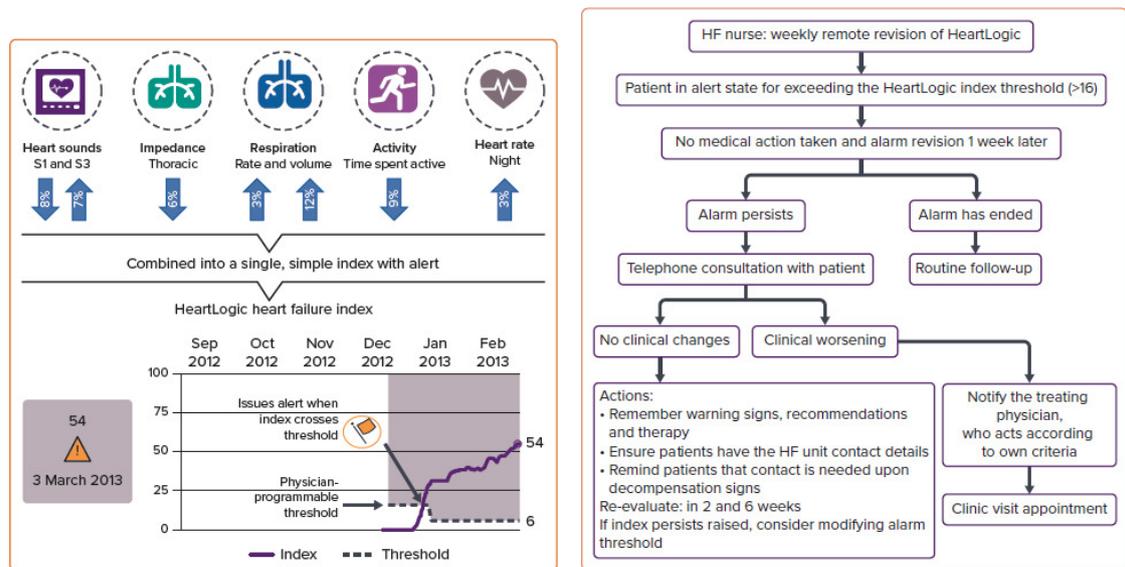


Figura 5.13. Monitoramento remoto digital para diagnósticos médicos. Fonte: [Letchumanan et al., 2020].

Outro exemplo é relacionado à detecção de diversas doenças usando biossensores. Letchumanan et al. utilizaram biossensores de ouro nano-híbridos por serem altamente sensíveis e seletivos na detecção de biomacromoléculas clínicas circulantes. A integração desses biossensores, vide a Figura 5.13, com tecnologias de comunicação digital possibilitou o monitoramento remoto dessas biomacromoléculas, permitindo um acompanhamento contínuo e não invasivo da condição de saúde do paciente. Para esta aplicação, a nanotecnologia cumpre um importante papel, servindo de interface para os receptores de sinais biológicos. Segundo os autores desse estudo, a aplicação de telediagnóstico com dispositivos não invasivos e automatizados é capaz de monitorar uma variedade de doenças comuns, como hipertensão, diabetes, Parkinson e outras doenças neurológicas sem a necessidade de ações intensas por parte do paciente [Letchumanan et al., 2020].

López-Azor et al desenvolveram um sistema para monitoramento precoce de insuficiência cardíaca. Esse problema é melhor detectado por meio de múltiplas variáveis medidas em dispositivos cardíacos. Para tanto, propôs-se o uso do algoritmo *HeartLogic* implementado em alguns desfibriladores cardíacos, os quais são sensores/atuadores implantáveis. Com esse sistema de telemonitoramento, são monitorados a frequência cardíaca noturna, os movimentos respiratórios, a impedância torácica, a atividade física e a intensidade dos batimentos cardíacos. O algoritmo *HeartLogic* funciona como mostrado na Figura 5.14(a), onde diversas medidas são combinadas em um índice. As informações do algoritmo *HeartLogic* são transmitidas por meio de um comunicador ao sistema Latitude NXT, que é uma plataforma virtual de monitoramento remoto que pode ser acessada pela equipe médica para estratificação de pacientes de acordo com o risco de descompensação cardíaca. Nesse sistema, um paciente só estará ciente de um status de alerta do *HeartLogic* se for contatado diretamente por seu profissional de saúde. A lógica utilizada pelos profissionais é apresentada na Figura 5.14(b), a qual é chamada de *RE-HEART Registry Follow-Up Protocol* [López-Azor et al., 2022].



(a) Funcionamento do algoritmo HeartLogic.

(b) Funcionamento do protocolo *RE-HEART Registry Follow-Up*.

Figura 5.14. Proposta de sistema de telemonitoramento com sensores implantados para detecção precoce de insuficiência cardíaca. Fonte: [López-Azor et al., 2022]

Telemonitoramento com sensores vestíveis

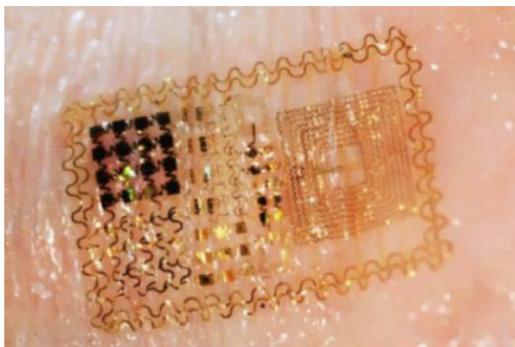
O uso de sensores vestíveis está cada vez mais popular em sistemas de telemonitoramento. Esses tipos de sensores são não invasivos e se enquadram em duas principais categorias: peles eletrônicas (e-skins), que são adesivos que aderem à superfície corporal, como mostrado na Figura 5.15(a); e dispositivos baseados em roupas ou acessórios onde a proximidade é suficiente, como mostrado na Figura 5.15(b). Esses dispositivos devem ser leves e de eletrônica flexível.

Esses tipos de sensores vem sendo utilizados para monitoramento de doença de Parkinson [Caballol et al., 2023], para detecção de ataques cardíacos [Amati et al., 2022] e reabilitação pós ataque cardíaco [Boukhenoufa et al., 2022], entre outros [Rodgers et al., 2015].

Telemonitoramento para o controle de avanço de doenças em cidades com sensores inteligentes

A tecnologia tem ajudado a indústria médica a rastrear e tratar vírus. Entre os exemplos mais recentes está o rastreamento da gripe. Em 2018, os EUA experimentaram uma temporada de gripe particularmente grave. Durante esse período, os dados agregados do usuário coletados por meio dos termômetros conectados inteligentes da Kinsa indicaram picos de doenças em todo o país [Healthcare Information and Management Systems Society (HIMSS), 2020].

Outras pesquisas indicam que sensores em *smartphones* podem permitir o monitoramento em tempo real de doenças infecciosas nos níveis populacional e doméstico. O



(a) Adesivo sensor para aplicação na pele, com capacidade de comunicação por WBAN. Fonte: [Rodgers et al., 2015]
 (b) Camisa com sensores para monitoramento de sinais vitais. Fonte: [Bedi, 2018]

Figura 5.15. Exemplos de sensores vestíveis.

estudo em [Miller et al., 2018] avalia o uso de dados de “termômetros inteligentes” disponíveis comercialmente, conectados a um aplicativo de celular, para vigilância de doenças semelhantes à influenza. Em nível populacional, foi analisada a correlação entre as gravações do termômetro e a atividade da influenza relatada pelos Centros de Controle e Prevenção de Doenças e por faixa etária e região. Foram desenvolvidos modelos de séries temporais para prever a atividade da influenza em tempo real e com até 3 semanas de antecedência.

Ainda no contexto de monitoração da população, os drones podem desempenhar um papel importante no gerenciamento de doenças, devido às suas diversas aplicações. Durante a pandemia de COVID-19, alguns países usaram drones para identificar pacientes e pessoas com situações e comportamentos de alto risco em grandes grupos populacionais [Mastaneh e Mouseli, 2020]. Essas ferramentas podem monitorar a temperatura das pessoas, frequência cardíaca e respiratória usando sensores, câmeras de alta resolução e sistemas de computação. Eles também exibem as atividades das pessoas, como espirros e tosse, o que ajuda a detectar casos suspeitos [Ruiz Estrada, 2020]. Outra aplicação dos drones é para serviços logísticos [Mastaneh e Mouseli, 2020]. Devido à necessidade de distanciamento social, água e comida, remédios, amostras de laboratório de pacientes e outros itens essenciais são transportados rapidamente por drones. Os drones também estão sendo usados para amplas operações de desinfecção aérea [Restás et al., 2021]. Esta técnica pode ser considerada para limpeza de superfície de áreas maiores.

O trabalho [Restás et al., 2021] estuda o efeito de três parâmetros relacionados ao drone, a vazão do líquido desinfetante pulverizado, a velocidade de voo e a altitude de voo durante a missão, na eficácia da operação de desinfecção. O uso adaptado de drones agrícolas também podem ser uma boa alternativa para desinfecção durante uma pandemia. Além de desinfetar locais e transportar materiais, os drones também podem ser utilizados para conscientização da população com relação aos conselhos de saúde para pessoas com comportamentos de alto risco, bem como os anúncios do governo durante a

quarentena [Mastaneh e Mouseli, 2020].

Telemonitoramento com redes sociais

Depressão, cognição prejudicada, falta de sono são exemplos de problemas e sintomas que podem ser monitorados por meio do uso de tecnologias não invasivas [Salman et al., 2021]. O artigo [Besaleva e Weaver, 2016] discutiu as vantagens do uso de aplicativos de mídia social em sistemas de saúde. Os autores descobriram que os aplicativos de mídia social são muito benéficos para os sistemas de saúde. Essa constatação pode ser justificada pelo fato de tais aplicativos conterem uma enorme quantidade de informações úteis que estão sempre disponíveis online e facilmente acessíveis. Os sites de mídia social podem fornecer conhecimento detalhado sobre os usuários (por exemplo, o Facebook sabe sua idade, status de relacionamento, cargo, preferências musicais e assim por diante), incluindo informações sobre saúde.

Outros exemplos de tecnologias da Web 2.0 podem ser encontrados nas áreas de saúde e bem-estar social. Sites que fornecem experiências e conselhos em primeira pessoa tornam mais fácil para pacientes se abrirem sobre suas condições e pedirem ajuda. Por exemplo, o site PatientsLikeMe¹³ fornece um fórum para que as pessoas compartilhem com segurança tratamentos, sintomas e experiências com seus colegas. Além disso, existem muitas redes sociais para pacientes ou amigos e familiares. Eles são úteis para conectar pessoas que precisam de apoio para lidar com o luto ou para compartilhar suas histórias. A importância dessas redes sociais comunitárias foi reconhecida por várias autoridades, incluindo a Cruz Vermelha [Besaleva e Weaver, 2016].

5.3.5. Propostas para Telerreabilitação

A telerreabilitação é uma modalidade de tratamento que consiste em utilizar tecnologias de informação e comunicação para realizar o acompanhamento e tratamento de pacientes em recuperação de lesões, cirurgias ou doenças crônicas.

Durante a pandemia por Sars-Cov-2, o distanciamento social passou a ser uma necessidade, mudando a forma do manejo de pacientes, passando a implementar estratégias para que a comunidade não ficasse desassistida de atendimento [Bitar e Alismail, 2021]. Esse fato acabou catalisando processos que podem facilitar o acompanhamento e reabilitação de pacientes em seu ambiente domiciliar, sem que seja necessário o cansativo deslocamento destes pacientes em um movimento pendular de casa para a clínica e da clínica para casa várias vezes por semana [Santos et al., 2020b].

Opções de telerreabilitação podem auxiliar muito os pacientes que nesse período tiveram que se adaptar a não poderem sair de casa, ou mesmo que têm limitações, sejam elas físicas ou mesmo socioeconômicas. Esta adaptação é uma estratégia que tende a ser bem aceita pelos usuários com relevante tendência a mudar o cenário de tratamento e de monitoramento de pacientes com doenças crônicas não transmissíveis [Bitar e Alismail, 2021]. O tratamento com esses pacientes tem um impacto positivo, pois o paciente se sente acolhido pela instituição, e sem a reabilitação, a grande maioria dos pacientes está fadada à inatividade, fator esse que interfere de forma impactante na retomada das atividades de vida diárias (AVDs), muitas vezes desprovidos de orientação profissional mais

¹³www.patientslikeme.com

técnica [Seron et al., 2021].

O teleatendimento dentro do processo da reabilitação cardiovascular (RCV) e pulmonar pode ser considerado como um tratamento com efetividade fundamentada em evidências científicas, e indicada a pacientes com disfunções cardiorrespiratórias e metabólicas crônicas no cenário das doenças cardiovasculares (DCVs) e das doenças respiratórias crônicas [Santos et al., 2020b, Omboni et al., 2022]. Os objetivos principais dos programas de telessaúde no âmbito da RCV são, *(i)* melhorar a performance física e psíquica do indivíduo, *(ii)* estimular o autocontrole da enfermidade, e *(iii)* promover o engajamento às mudanças do estilo de vida [Omboni et al., 2022].

Os programas de atendimento por telessaúde, ou telerreabilitação, podem ser considerados como intervenções que incluem a avaliação, a terapia por treinamento com exercícios individualizados, e o autocuidado, através de aconselhamento e educação sobre sua condição funcional [Seron et al., 2021]. O principal componente dessa intervenção é a terapia por treinamento muscular, que por sua vez leva à melhora dos sintomas cardiorrespiratórios tais como a dispneia, a fadiga, a intolerância ao exercício, e consequentemente melhora da qualidade de vida [Miller et al., 2021].

Programas de 8 a 12 semanas de telerreabilitação podem promover benefícios e, todavia, há necessidade de sustentar esse ganho, que pode ser perdido meses após o término do programa. A manutenção dos benefícios desses programas tem sido foco de pesquisa entre investigadores, com o intuito de completar ou mesmo suprir as intervenções convencionais de RCV realizadas em ambulatórios, centros de reabilitação, que por sua vez estão restritas ao acesso a apenas uma pequena parcela da população estimada em aproximadamente 5% [Seron et al., 2021]. O percentual de evasão do tratamento é de 50% e uma taxa de abandono que chega a 32% [Lalonde, 2012]. Dentre os motivos que contribuem para a recusa ou a redução da participação dos pacientes nos programas de tratamento e reabilitação estão: *(i)* a alteração da rotina diária para poder participar, *(ii)* as péssimas condições de transporte urbano, e *(iii)* o horário específico das sessões e *(iv)* os limites funcionais originados pela própria enfermidade, assim como pelas comorbidades associadas. O aumento da incapacidade funcional decorrente da doença e o medo de dispneia intensa interferem também negativamente na participação em programas de RCV [Seron et al., 2021, Lau e McAlister, 2021].

Dentre os principais fatores que contribuem positivamente para a adesão ao tratamento, conforme a opinião dos pacientes que participaram de modelos de programas de telerreabilitação, destacam-se: *(i)* os componentes educacionais de monitoramento e de avaliações clínicas seriadas, *(ii)* a facilidade no uso dos equipamentos, *(iii)* a segurança em ser monitorado regularmente e *(iv)* o conforto por estar envolvido no gerenciamento de sua própria condição de saúde.

Uma diretriz americana de prática clínica com treinamento na insuficiência cardíaca (IC), abordou a adesão dos pacientes a intervenções baseadas em exercícios. Os autores relatam que existem poucas evidências de intervenções para melhorar a adesão, devido a uma ampla variedade de intervenções e medidas, a maioria das quais são baseadas em auto relato. A falta de uma mensuração objetiva impediu que a diretriz descrevesse ações importantes sobre esse tópico e, portanto, ponderam que os profissionais devem considerar estratégias para melhorar a adesão ao prescrever os principais exercí-

cios para a reabilitação dos pacientes com IC [Shoemaker et al., 2020]. Há, portanto, uma necessidade de desenvolver novas estratégias de tratamento mais acessíveis e disponíveis para a população de pacientes com DCRs [Williams et al., 2018].

Em parceria com a Clínica Coração Valente da UFF, foi desenvolvido um aplicativo mobile e uma interface web, com a finalidade de agendar os exercícios domiciliares para lembrar os pacientes de realizá-los no horário prescrito, bem como coletar os dados da realização ou não dos exercícios [Seixas et al., 2021]. O sistema permite ao profissional da saúde a prescrição de exercícios, e o agendamento de notificação para realização do exercício. O paciente, então, após receber a notificação, confirma pelo aplicativo a realização do exercício no horário determinado. O profissional da saúde pode acompanhar a realização, ou não, do exercício cardio-respiratório através da confirmação do paciente e do registro dos efeitos após a realização da atividade.

As tecnologias relacionadas ao atendimento por telessaúde e telerreabilitação também têm sido aplicadas na área da quimioterapia. O câncer pediátrico é a doença crônica que apresenta a maior taxa de mortalidade na faixa etária entre 0 e 19 anos. Durante muitos anos, a terapia antineoplásica intravenosa foi a única opção disponível, e os serviços de saúde foram estruturados de acordo com esse modelo de tratamento [Mesquita et al., 2018]. A quimioterapia antineoplásica é definida principalmente como o uso de substâncias químicas isoladas ou em combinação que interferem diretamente no processo de crescimento e divisão celular, com o objetivo de tratar neoplasias malignas [Bonassa e Gato, 2012]. No entanto, seu uso pode causar uma série de efeitos adversos e toxicidades, pois atua inespecificamente, afetando células de rápida proliferação, incluindo aquelas que não são neoplásicas. As toxicidades e efeitos adversos mais comuns incluem os hematológicos, infecciosos e gastrointestinais, bem como cistite hemorrágica, neurológica, pulmonar, disfunção cardíaca e reações alérgicas [Iuchno e De Carvalho, 2019].

Com a introdução dos antineoplásicos orais, houve uma necessidade de reorganização das práticas educacionais para o autocuidado envolvendo esses medicamentos, uma vez que a eficácia da quimioterapia oral domiciliar depende da eficiência do autocuidado. Os familiares de crianças e adolescentes que utilizam antineoplásicos orais devem receber orientações e acompanhamento de uma equipe multidisciplinar. A orientação adequada é fundamental nesse processo, pois guia o uso correto, monitora reações adversas e interações medicamentosas, reduzindo os riscos de erros e interrupção do tratamento. Além disso, a participação da família nos cuidados é essencial, uma vez que o uso de quimioterapia antineoplásica oral em casa requer que a família administre o medicamento à criança ou ao adolescente [da Silva et al., 2015].

Neste contexto, o aplicativo QuímioEmCasa tem por objetivo orientar familiares de crianças e adolescentes quanto ao tratamento de quimioterápicos orais, servindo também como diário de bordo onde familiares podem consultar sobre como armazenar medicações antineoplásicas orais, receber notificações, e reportar efeitos colaterais. Esses registros são recebidos por um profissional de saúde que pode, nesse momento, acompanhar o histórico do paciente, ou decidir por realizar alguma intervenção. [Franco et al., 2022]. Para o desenvolvimento do aplicativo, foram entrevistados familiares de crianças e adolescentes com câncer, a fim de entender as principais dúvidas quanto ao tratamento com quimioterápicos antineoplásicos orais. Em seguida, foram descritos os conteúdos

que esses familiares consideram fundamentais para serem contemplados na elaboração do aplicativo móvel. O aplicativo foi desenvolvido em duas versões: a versão para desktop é destinada aos profissionais de saúde, onde é possível agendar para os familiares os dias e horários que o medicamento deve ser aplicado, e acompanhar as notificações dos familiares quanto ao estado de saúde do paciente. A versão mobile do aplicativo é destinada aos familiares, onde é possível receber notificações, informações preparadas por profissionais da saúde sobre o uso da medicação, e registrar os seus efeitos adversos. Espera-se assim melhorar a comunicação entre os familiares, pacientes e profissionais de saúde, elevar segurança do paciente e a eficiência do tratamento quimioterápico.

Outras áreas de aplicação da telerreabilitação incluem áreas da fisioterapia. Alguns estudos sugerem que fisioterapia por telessaúde com provedores de terapia e/ou avatares virtuais tem sido benéfica para pacientes, provedores e o sistema de saúde em geral. Os programas de terapia virtual com avatares ajudam os pacientes com exercícios enquanto os gravam em vídeo 3-D e fornecem *feedback* em tempo real, como mostrado na Figura 5.16 [Siddiqi e PiuZZi, 2021].

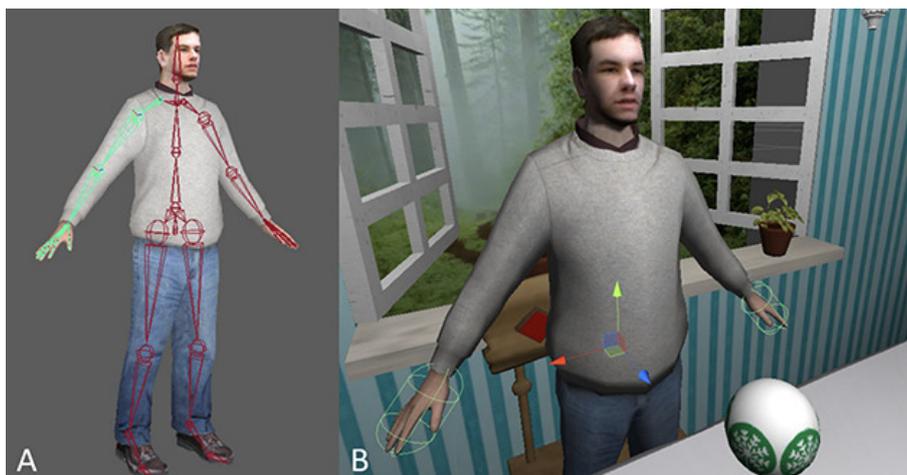


Figura 5.16. Telerreabilitação usando avatares. Fonte: [Siddiqi e PiuZZi, 2021].

Outros trabalhos sugerem o uso de óculos de realidade virtual para a realização de atividades de reabilitação remota. Essas plataformas permitem que cirurgiões e fisioterapeutas prescrevam e monitorem remotamente exercícios específicos que o paciente realiza em suas próprias casas [Bini et al., 2020].

5.3.6. Telecirurgia

A telecirurgia é uma modalidade da telemedicina que conecta pacientes e médicos cirurgiões localizados em locais distintos durante o ato cirúrgico. A telecirurgia pode ser classificada em três categorias de acordo com o tipo de assistência remota: telementoria, suporte telecirúrgico e telecirurgia completa. A telementoria é o processo de fornecer instruções de um local remoto, de um cirurgião especialista para um cirurgião generalista. O suporte telecirúrgico é o ato no qual o cirurgião remoto auxilia na cirurgia com o uso de um robô. Por fim, na telecirurgia completa, toda a cirurgia é realizada a partir de um local remoto, permitindo que o cirurgião possa realizar a cirurgia remotamente por meio de um

sistema robótico. Apesar de inúmeros estudos realizados em todo o mundo, a aplicação da telecirurgia completa ainda não é possível [Oki et al., 2023].

A telecirurgia é interessante para que um cirurgião especialista possa atender pacientes em locais remotos ou em situações emergenciais. Em muitos casos, o deslocamento do médico ou do paciente pode ser muito caro ou inviável, seja pela condição de saúde do paciente, seja pela agenda do médico cirurgião, abrindo espaço para esse tipo de atividade.

Embora seja interessante, esse tipo de técnica deve ser aplicada com algumas considerações de segurança. Um relatório da Universidade de Illinois concluiu que de 2004 a 2019, pelo menos 144 mortes e 1.391 ferimentos ocorreram com cirurgias robóticas nos Estados Unidos. As falhas ocorreram devido a problemas no fornecimento de energia, erros de sistemas e problemas de rede, incluindo altas latências [Gupta et al., 2019].

Alguns artigos sugerem que os problemas de atrasos em rede podem ser solucionados com tecnologias com as redes de telefonia celular 5G [Gupta et al., 2019, Oki et al., 2023, Gonzalez et al., 2023, Lin e Lue, 2023], que oferecem classes de serviço com alta confiabilidade e baixa latência, no chamado *Ultra-Reliable Low-Latency Communication* (URLLC) [Neto et al., 2023]. A recomendação de [Gupta et al., 2019] é de que a rede seja capaz de prover latências inferiores a 10 ms [Gupta et al., 2019], embora esse requisito possa ser complexo de ser atendido em cirurgias realizadas a longa distância. Já Ebihara et al indicam estudos que apontam que atrasos inferiores a 200 ms já são suficientes para operar robôs remotamente, embora atrasos inferiores a 100 ms sejam uma recomendação mais segura [Ebihara et al., 2022].

5.3.6.1. Uso de robôs na telecirurgia

Entre os experimentos já realizados pelo mundo, destaca-se a primeira colecistectomia clinicamente remota realizada no mundo, com o sistema robótico ZEUS e a rede *Transatlantic Optical Faber Network*. A telecirurgia utilizou uma linha dedicada de 10 Mb/s [Marescaux et al., 2001] e abriu o caminho para a realização de diversos outros experimentos.

Outro caso de destaque aconteceu nos EUA, em um experimento no Florida Hospital, no qual telecirurgias assistidas por robô foram realizadas por cirurgiões no Texas, que fica a cerca de 1900 km de distância. O robô utilizado foi o da Vinci, e as cirurgias foram em pacientes simulados via Internet [Sterbis et al., 2008].

Pesquisadores no Japão realizaram uma pesquisa para definir requisitos para a realização de telecirurgias com suporte robótico [Ebihara et al., 2022]. Para tanto, salas de operação foram montadas nos hospitais universitários da *Hokkaido University* e da *Kyushu University*, as quais estão a uma distância de aproximadamente 2000 km e conectadas pela rede SINET (*Science Information NETWORK*). A SINET é uma rede não comercial para a ciência, com um backbone com cobertura nacional a 100 Gb/s, que conecta por volta de 1000 universidades e centros de pesquisa no Japão. Para o experimento, foi criado um circuito virtual entre as duas universidades com capacidade configurável entre 100 e 500 Mb/s. Os fluxos de vídeos eram codificados com H.265, em um esquema conforme mostrado na Figura 5.17.

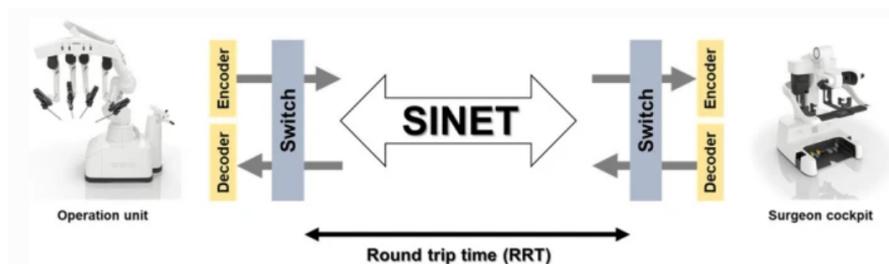


Figura 5.17. Experimento japonês para definição de requisitos para a telecirurgia.
 Fonte: [Ebihara et al., 2022].

Para o experimento, utilizou-se o sistema robótico cirúrgico japonês chamado de Hinotori, desenvolvido pela Medicaoid Corporation, com um sistema endoscópico chamado de Karl Storz™ 3D. Os resultados mostraram que taxas inferiores a 150 Mb/s já levavam a perdas de pacote que impactavam as imagens.

Esses exemplos demonstram que a telecirurgia ainda é um campo em aberto com diversos desafios, dada a alta criticidade da atividade. Falhas técnicas podem ter um alto impacto, custando a vida do paciente, mas novas evoluções tecnológicas trazem novas oportunidades para esse campo da telemedicina.

5.3.6.2. Telecirurgia com realidade aumentada

A realidade aumentada (*Augmented Reality* - AR) é um dos pontos fortes vislumbrados para o futuro da cirurgia, pela possibilidade de trazer ao cirurgião dados extras que estão conectados e podem ajudar na realização do ato cirúrgico, como a colocação de imagens de exames ao lado do campo cirúrgico.

O uso da AR na teleinterconsulta cirúrgica já vem demonstrando o seu potencial em diversos sistemas propostos recentemente. Maria et al propõem o uso de *AR-Head Mounted Displays* (AR-HMD) para aproximar cirurgiões de sistemas de imagens que precisam ser visualizados durante a cirurgia e disponibilizar um sistema interativo com ferramentas de gestos para apontar e anotar em imagens compartilhadas e no ambiente físico. Com o sistema proposto, cirurgiões remotos e presenciais conseguem interagir, marcando lugares apontados, facilitando a compreensão de recomendações passadas pelo especialista remoto [Maria et al., 2023].

Song et al propõem um sistema semelhante, chamado de ARC-MeD, mostrado na Figura 5.18. O ARC-MeD permite a interação entre médicos no centro cirúrgico e médicos remotos, que podem interagir por meio de imagens em uma tela. Todos os usuários podem adicionar anotações a essa tela e o cirurgião pode escolher uma parte da tela para aproximar da sua visualização [Song et al., 2022].

Esses tipos de proposta são alvos de estudo por todo mundo. A Figura 5.19 mostra a incidência de trabalhos publicados em mapeamento 3D e realidade aumentada para telecirurgia em função do país.

péia, lidando com implementação de pilotos de larga escala e desenvolvimento de plataformas financiados pela Comissão Europeia no âmbito da Digitalização das Indústrias Europeias (DEI). Entre as áreas de foco, tem-se a telessaúde. Especificamente para a telessaúde, o OPEN DEI tem os projetos ICU4COVID¹⁵, Smart4Health¹⁶, ERN-ACT¹⁷ e DS4Health¹⁸. Além disso, existe uma iniciativa para criação de uma rede digital de telessaúde transnacional na Europa, para criação de telemedicina e teleassistência integradas. Nesse contexto, estão sendo criados Centros de Telessaúde em mais de 12 países e regiões, os quais estão relacionados com os Centros de Inovação Digital (*Digital Innovation Hubs* - DIH¹⁹) financiados pela UE e as Redes Europeias de Referência (*European Reference Network* - ERN²⁰).

Uma inovação considerável nesse contexto é o uso da telemedicina nas UTIs, por meio de teleinterconsultas. Com esse projeto, chamado de Telnet@NRW²¹, hospitais periféricos estão sendo conectados digitalmente com centros especializados de excelência. Especificamente, esse projeto contou com mais de 150.000 participantes do estudo e mais 10.500 pacientes tratados.

Outra iniciativa interessante da Europa é a United4Health²², parcialmente financiada pelo Programa de Apoio à Política de TIC (ICT PSP) como parte do Programa Estrutural de Competitividade e Inovação (CIP) da Comunidade Européia. O objetivo dessa iniciativa é explorar e implantar serviços inovadores de telemedicina desenvolvidos no contexto do projeto RENEWING HeALTH²³. Todas as soluções financiadas usam a abordagem centrada no paciente, contando com telemonitoramento de pacientes com doenças crônicas, como diabetes, doenças pulmonares (DPOC) ou cardiovasculares.

Outra iniciativa relevante é a *Africa Telehealth*²⁴, a qual é promovida por uma organização sem fins lucrativos do Canadá. A proposta é incentivar iniciativas para melhorar a saúde na África por meio de tecnologias de informação e comunicação (TICs), levando informação, tecnologia e treinamento aos profissionais médicos africanos.

No Brasil, um dos projetos em destaque é o Projeto e-Health Rio, que visa a construção de uma rede para o desenvolvimento de atividades de pesquisa e inovação relacionadas à aplicação de Tecnologias da Informação e Comunicação à saúde digital, mais especificamente a Doenças Crônicas Não Transmissíveis (DCNTs). O projeto, que inclui pesquisadores da UFF, UFRJ, UERJ e LNCC, visa áreas como sistemas de apoio à decisão, uso de efeitos sensoriais em exercícios cognitivos, análise de imagens termográficas para detecção de tumores, entre diversos outros temas que estão sendo aplicados dentro do contexto da telessaúde. As atividades do projeto estão estruturadas em cinco

¹⁵<https://www.icu4covid.eu/>

¹⁶<https://smart4health.eu/>

¹⁷<https://www.ernact.eu/>

¹⁸<https://www.developmentaid.org/organizations/awards/view/407914/digital-skills-for-healthcare-transformation-ds4health>

¹⁹<https://digital-strategy.ec.europa.eu/en/activities/edihs>

²⁰https://health.ec.europa.eu/european-reference-networks_en

²¹<https://www.telnet.nrw/>

²²<https://ehel.eu/activities/eu-funded-projects/united4health.html>

²³<https://healthcare-in-europe.com/en/news/the-renewing-health-european-project.html>

²⁴<https://www.comminit.com/content/africa-telehealth-project>

grandes temas, que são: doenças neurodegenerativas, câncer de mama e tireóide, doenças psiquiátricas, monitoramento remoto de pacientes cardíacos e telessaúde. Os principais objetivos do projeto são sistemas de apoio à decisão clínica; exercícios cognitivos multimídia com efeitos sensoriais para auxílio a terapias; proposta de novas técnicas de modelagem numérica por elementos finitos, processamento e análise de imagens termográficas para detecção de tumores da mama e da tireóide; desenvolvimento e aplicação de técnicas de inteligência artificial para identificar padrões cerebrais que melhor discriminam estados emocionais e predizem sintomas psiquiátricos; proposta de novos protocolos de comunicação para redes corporais sem fio para monitoramento eficiente de pacientes cardíacos; desenvolvimento de sistemas de suporte à teleinterconsulta; desenvolvimento técnicas para construção de um sistema de prontuários baseado em blockchain para uso distribuído, seguindo padrões internacionais de armazenamento de dados e garantindo a privacidade, o controle de acesso e o anonimato dos dados para uso em pesquisa.

Outro projeto de grande relevância no Brasil é o projeto Teleconferência de Ato Cirúrgico (TAC). Esse projeto objetiva melhorar o atendimento cirúrgico no Brasil, com foco em regiões remotas ou com menos recursos, as quais usualmente não contam com médicos especialistas cirurgiões. O TAC disponibiliza uma plataforma digital aberta, que está sendo desenvolvida pelo Instituto de Tecnologia FIT e a Cisco Brasil, para acompanhamento do ato cirúrgico por médicos especialistas. No caso de estudo que vem sendo desenvolvido com a plataforma, médicos especialistas do InCor acompanham cirurgias de alta criticidade realizadas em diversos hospitais do país. Para tanto, esses hospitais devem ter uma sala preparada com câmeras, microfones e iluminação adequada. Além do acompanhamento em tempo real da cirurgia por diversas câmeras, a plataforma salva os vídeos do procedimento na nuvem. Assim, as imagens geradas podem ser utilizadas para fins de tele-educação, posteriormente, por meio de um player, como mostrado na Figura 5.20.

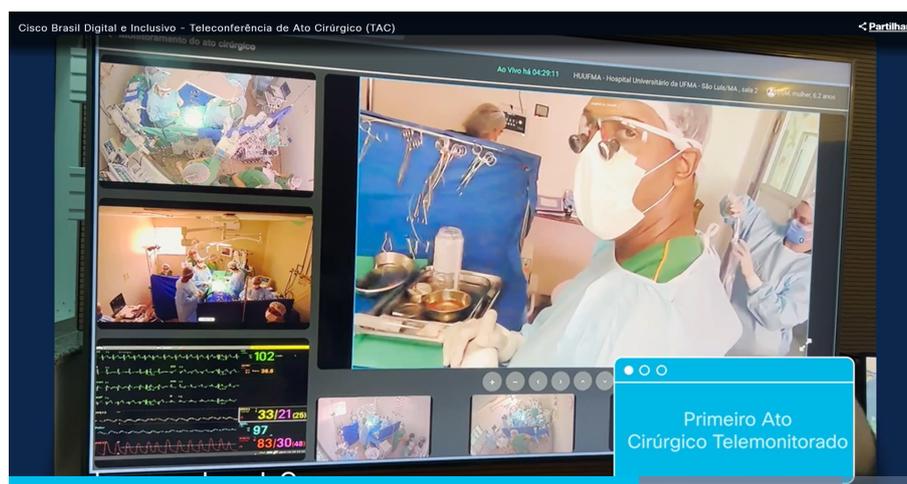


Figura 5.20. Imagem da primeira telecirurgia com o TAC, aonde uma cirurgia no Pará foi assistida pelos especialistas do InCor. Destacam-se os equipamentos especiais que devem ser usados pelo cirurgião para captura de parte das imagens. Fonte: [William et al., 2018].

De fato, existem inúmeros projetos que visam diferentes objetivos pelo mundo. Pode-se destacar a iniciativa americana para suporte a crianças com autismo [Schieltz

et al., 2022]; o projeto californiano para acompanhamento de crianças, jovens e adolescentes transgênero que sofrem dificuldades no acesso aos centros de atendimento [Russell et al., 2022]; o *MOTHeRS Project*, que visa à assistência a gestantes e recém-nascidos em áreas rurais na Carolina do Norte [Atezaz Saeed et al., 2023]; o *Video Visits for Elders Project* (VVEP), que iniciou na pandemia de COVID-19 para permitir a visita virtual a idosos em estado de vulnerabilidade em casas de repouso [Chu et al., 2022]; além de outras iniciativas de sucesso na Europa, Ásia e África [John et al., 2022, Pires et al., 2022].

5.4.1. Desafios de pesquisa

Fica muito claro o interesse estratégico da telessaúde pelo mundo, tanto visando a redução de custos quanto a melhoria da qualidade de atendimento do paciente. A expectativa é de grandes investimentos em pesquisa nessas áreas, em especial no desenvolvimento de novas tecnologias de suporte e sistemas. Também se esperam grandes investimentos em projetos com foco na eficiência das diferentes técnicas de telessaúde, com foco na definição de protocolos médicos eficazes e seguros.

Um desafio de pesquisa relacionado à telessaúde é estudar a eficácia das intervenções de telessaúde em comparação com o atendimento presencial tradicional. Isso requer consideração cuidadosa de fatores, incluindo a satisfação do paciente, resultados clínicos e custos de saúde [Choudhury et al., 2022] [Scalvini et al., 2004]. Um dos principais desafios do estudo da eficácia da telessaúde é o potencial de viés de seleção. Os pacientes que optam por receber serviços de telessaúde podem diferir sistematicamente daqueles que recebem atendimento presencial, o que pode confundir os resultados de qualquer comparação. Os pesquisadores devem levar em conta essas diferenças usando técnicas estatísticas apropriadas ou conduzindo ensaios controlados randomizados que designam pacientes aleatoriamente para telessaúde ou atendimento pessoal [Choudhury et al., 2022, Fahmy, 2020, Latifi et al., 2020, Scalvini et al., 2004].

Outro desafio é garantir que as intervenções de telessaúde sejam implementadas de forma correta e consistente em diferentes provedores e ambientes. Por exemplo, as visitas de telessaúde podem exigir diferentes habilidades de comunicação ou experiência em tecnologia que não são necessárias em visitas presenciais, o que pode afetar a qualidade do atendimento prestado [Fahmy, 2020, Latifi et al., 2020]. Os pesquisadores também devem considerar o potencial de dificuldades técnicas ou problemas com o acesso do paciente à tecnologia. Por fim, há considerações éticas relacionadas ao uso da telessaúde, incluindo garantir a privacidade do paciente e o consentimento informado, além de abordar possíveis disparidades no acesso à tecnologia e aos cuidados [Scalvini et al., 2004]. Essas questões devem ser cuidadosamente consideradas nos estudos de pesquisa em telessaúde.

5.5. Considerações Finais

Uma oportunidade de telessaúde é a capacidade de fornecer serviços de saúde a populações carentes, incluindo aquelas que vivem em áreas rurais ou remotas ou com acesso limitado a instalações de saúde [Latifi et al., 2020, Scalvini et al., 2004]. A telessaúde pode ajudar a preencher a lacuna no acesso à saúde, fornecendo consultas remotas, visitas virtuais e monitoramento remoto para pacientes que podem não ter acesso aos serviços de saúde de outra forma [Choudhury et al., 2022]. Por exemplo, os pacientes que

vivem em áreas rurais podem enfrentar desafios significativos no acesso aos cuidados de saúde devido ao longo tempo de viagem e à disponibilidade limitada de profissionais de saúde. A telessaúde pode permitir que esses pacientes se conectem com os profissionais de saúde remotamente, reduzindo a necessidade de viagens e melhorando o acesso aos cuidados.

Além disso, a telessaúde também pode ajudar a lidar com a escassez de profissionais de saúde, principalmente em especialidades como saúde mental e atenção primária. Ao permitir que os prestadores de cuidados de saúde prestem cuidados remotamente, a telessaúde pode ajudar a expandir o acesso aos cuidados e melhorar a distribuição dos recursos de saúde [Fahmy, 2020]. A telessaúde também apresenta oportunidades para organizações de saúde otimizarem suas operações e reduzirem custos. Por exemplo, as visitas de telessaúde podem reduzir a necessidade de visitas pessoais, o que pode ajudar a reduzir os custos das unidades de saúde e melhorar a eficiência. A telessaúde oferece oportunidades para os profissionais de saúde melhorarem o envolvimento e a comunicação do paciente. Ao fornecer aos pacientes acesso a visitas virtuais e ferramentas de monitoramento remoto, os profissionais de saúde podem se comunicar mais facilmente com seus pacientes e monitorar seu estado de saúde, levando a melhores resultados de saúde [Latifi et al., 2020, Scalvini et al., 2004].

Dessa forma, com as novas tecnologias, profissionais da saúde podem assistir pacientes em áreas remotas tornando o acesso à saúde ilimitado, dando muitas vezes acesso a tratamentos que só seriam alcançáveis nos grandes centros urbanos do país, onde a estrutura de saúde é mais avançada. No Brasil, a Telessaúde ocorre em alguns cenários que a maioria da população sequer imagina, como, por exemplo, nas comunidades ribeirinhas, indígenas da Amazônia, na atenção básica e na atenção especializada, com variado alcance e sofisticação. Então, alinhada às dificuldades geográficas do país pelo seu tamanho continental, áreas de difícil acesso, locais em que a rede de saúde local é insuficiente ou apresenta gargalos não facilmente corrigíveis como a desproporção de profissionais de saúde nas diferentes regiões do país, a Telessaúde surge como uma ferramenta resolutiva para a falta de acesso a uma estrutura pública e privada de saúde para as diferentes populações que compõem o território nacional. Isso fica explícito se pensarmos na diferença entre a zona sul do Rio de Janeiro ou São Paulo e suas comunidades periféricas, assim como entre uma cidade como Manaus e uma aldeia indígena no rio Xingu no próprio estado do Amazonas.

A Telessaúde tem se mostrado então, uma solução a se aliar na luta por trazer qualidade à assistência, sem tornar o custo proibitivo. Esta será uma estratégia de saúde pública para tentar homogeneizar o atendimento de saúde em um ambiente tão diverso, com populações que têm diferenças culturais, regionais, étnicas, de renda e de aparelhos públicos. Ela será uma alternativa quando a opção presencial não permitir resposta às demandas locais das populações não atendidas por métodos tradicionais. Ela levará às comunidades mais periféricas do centro político, econômico e social do país acesso a um bem público garantido pela constituição, permitindo que pessoas tenham direitos antes impossíveis de serem alcançados, democratizando a capacidade de um tratamento digno de saúde.

No caso da atenção básica, a Telessaúde é uma ferramenta importante para permi-

tir o acesso à saúde, fazendo com que a promoção da saúde ocorra. Objetivamente, ela trará conhecimento da comunidade assistida e desta forma, dados importantes para uma melhor compreensão desta população serão possíveis dando ensejo a novas e melhores abordagens ao local.

Não se pode deixar de lado o fato de que existem dilemas éticos presentes nesta modalidade de atendimento em rede, uma vez que essa consulta exigirá uma camada extra de cuidados com os dados do paciente que serão transmitidos por rede, a qual não poderá ficar vulnerável às interferências de pessoas mal intencionadas. Deste modo, a telessaúde demanda a segurança computacional no seu uso. Deste modo, a Telessaúde no Brasil tem passado por mudanças revolucionárias se consideradas as mudanças ocorridas no país nos últimos anos.

Referências

- [Acevedo et al., 2022] Acevedo, B. P., Dattatri, N., Le, J., Lappinga, C. e Collins, N. L. (2022). Cognitive training with neurofeedback using fNIRS improves cognitive function in older adults. *International Journal of Environmental Research and Public Health*, 19(9):5531.
- [Amati et al., 2022] Amati, F., Santobuono, V., Bozza, N., Latorre, M., Memeo, R. e Favale, S. (2022). Biosensors in cardiology. t-care project: a preliminary study on an innovative wearable telemonitoring system. *Europace*, 24(Supplement_1):euac053–589.
- [Andrès et al., 2019] Andrès, E., Meyer, L., Zulfiqar, A.-A., Hajjam, M., Talha, S., Bahougne, T., Ervé, S., Hajjam, J., Doucet, J., Jeandidier, N. et al. (2019). Telemonitoring in diabetes: evolution of concepts and technologies, with a focus on results of the more recent studies. *Journal of medicine and life*, 12(3):203.
- [Andrès et al., 2018] Andrès, E., Talha, S., Jeandidier, N., Meyer, L., Hajjam, M. e Hajjam, A. (2018). Telemedicine in chronic diseases: the time of maturity with telemedicine 2.0 in the setting of chronic heart failure and diabetes mellitus. *Curr Res Diabetes Obes J*, 6:1–4.
- [Atezaz Saeed et al., 2023] Atezaz Saeed, S., Jones, K., Sacks, A. J., Craven, K. e Xue, Y. L. (2023). Maternal outreach through telehealth for rural sites: The MOTHeRS project. *North Carolina Medical Journal*, 84(1).
- [Bai et al., 2020] Bai, L., Yang, D., Wang, X., Tong, L., Zhu, X., Zhong, N., Bai, C., Powell, C. A., Chen, R., Zhou, J. et al. (2020). Chinese experts' consensus on the internet of things-aided diagnosis and treatment of coronavirus disease 2019 (covid-19). *Clinical eHealth*, 3:7–15.
- [Beaklini et al., 2017] Beaklini, A. C., Vale, E. R., Filho, R. P., Dal Bello, J. C. R., Boechat, Y. E., Carrano, R. C. e Fernandes, N. C. (2017). Interiorização da medicina utilizando um sistema de telepresença holográfico. Em *Anais do XXIII Simpósio Brasileiro de Sistemas Multimídia e Web: Workshop do CT-Vídeo*, chapter 6. SBC, 1 edíÁ,,o.

- [Bedi, 2018] Bedi, S. (2018). Lighter, leaner, lifesaving: Af tests wearable medical tech. Acesso em 08 de junho de 2023.
- [Bertelli et al., 2022] Bertelli, M. O., Zorzi, S., Buonaguro, E. F., Bianco, A., Armellini, M. e Scattoni, M. L. (2022). Teleassistance and telerehabilitation: Covid-19, other epidemic situations and future prospects. Em Bertelli, M. O., Deb, S. S., Munir, K., Hassiotis, A. e Salvador-Carulla, L., editors, *Textbook of Psychiatry for Intellectual Disability and Autism Spectrum Disorder*, p. 1031–1050. Springer International Publishing.
- [Besaleva e Weaver, 2016] Besaleva, L. I. e Weaver, A. C. (2016). Applications of social networks and crowdsourcing for disaster management improvement. *Computer*, 49(5):47–53.
- [Bhatt e Bhatt, 2021] Bhatt, A. B. e Bhatt (2021). *Healthcare Information Technology for Cardiovascular Medicine*. Springer.
- [Bini et al., 2020] Bini, S. A., Schilling, P. L., Patel, S. P., Kalore, N. V., Ast, M. P., Maratt, J. D., Schuett, D. J., Lawrie, C. M., Chung, C. C. e Steele, G. D. (2020). Digital orthopaedics: A glimpse into the future in the midst of a pandemic. *The Journal of Arthroplasty*, 35(7, Supplement):S68–S73. Special COVID-19 Supplement.
- [Bitar e Alismail, 2021] Bitar, H. e Alismail, S. (2021). The role of ehealth, telehealth, and telemedicine for chronic disease patients during covid-19 pandemic: A rapid systematic review. *Digital health*, 7:20552076211009396.
- [Bloom et al., 2022] Bloom, P. P., Ventoso, M., Tapper, E., Ha, J. e Richter, J. M. (2022). A telemonitoring intervention for cirrhotic ascites management is cost-saving. *Digestive Diseases and Sciences*, 67(3):854–862.
- [Boechat et al., 2017] Boechat, Y. E. M., Dal Bello, J. C. R., Fernandes, N. C. e Moreira, T. B. (2017). Telessaúde: a assistência remota ao idoso por consulta on line on time através da holografia, uma inovação na medicina. Em *IX Congresso de Geriatria e Gerontologia do Estado do Rio de Janeiro - GeriatRio 2017*.
- [Bonassa e Gato, 2012] Bonassa, E. M. A. e Gato, M. I. R. (2012). Terapêutica oncológica para enfermeiros e farmacêuticos. Em *Terapêutica oncológica para enfermeiros e farmacêuticos*, p. 644–644.
- [Boukhenoufa et al., 2022] Boukhenoufa, I., Zhai, X., Utti, V., Jackson, J. e McDonald-Maier, K. D. (2022). Wearable sensors and machine learning in post-stroke rehabilitation assessment: A systematic review. *Biomedical Signal Processing and Control*, 71:103197.
- [Brasil, 2007] Brasil (2007). Portaria 35º/2007. *Diário Oficial União*.
- [Brasil, 2022] Brasil (2022). Resolução nº 2.314/2002. *Diário Oficial União*.
- [Brito et al., 2016] Brito, T. D. d. L. V., de Lima Lopes, P. R., Haddad, A. E., Messina, L. A. e Pisa, I. T. (2016). Análise da colaboração nos grupos de interesse especial da rede universitária de telemedicina (rute). *Journal of Health Informatics*, 8(1).

- [Caballol et al., 2023] Caballol, N., Bayés, À., Prats, A., Martín-Baranera, M. e Quispe, P. (2023). Feasibility of a wearable inertial sensor to assess motor complications and treatment in parkinson's disease. *Plos one*, 18(2):e0279910.
- [Cardenas et al., 2020] Cardenas, J., Gutierrez, C. A. e Aguilar-Ponce, R. (2020). Effects of antenna orientation in fall detection systems based on wifi signals. Em *2020 IEEE Latin-American Conference on Communications (LATINCOM)*, p. 1–6.
- [Cateb et al., 2021] Cateb, G. F., Amaral, S., Gonçalves, S. C., Oliveira, I. J., Prates, R. O., Chagas, B. A., Marcolino, M. S. e Reis, Z. S. (2021). Estudo piloto de validação de um chatbot de rastreamento, implementado para direcionar a teleassistência em covid-19. Em *Anais Estendidos do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, p. 97–102. SBC.
- [Chagas et al., 2021] Chagas, B. A., Ferregueti, K., Ferreira, T. C., Prates, R. O., Ribeiro, L. B., Pagano, A. S., Reis, Z. S. e Meira Jr, W. (2021). Chatbot as a telehealth intervention strategy in the covid-19 pandemic: lessons learned from an action research approach. *Latin-American Center for Informatics Studies Electronic Journal*.
- [Charpentier et al., 2011] Charpentier, G., Benhamou, P.-Y., Dardari, D., Clergeot, A., Franc, S., Schaepelynck-Belicar, P., Catargi, B., Melki, V., Chaillous, L., Farret, A. et al. (2011). The diabeo software enabling individualized insulin dose adjustments combined with telemedicine support improves hba1c in poorly controlled type 1 diabetic patients: a 6-month, randomized, open-label, parallel-group, multicenter trial (telediab 1 study). *Diabetes care*, 34(3):533–539.
- [Choudhury et al., 2022] Choudhury, T., Katal, A., Um, J.-S., Rana, A. e Al-Akaidi, M. (2022). *Telemedicine: The Computer Transformation of Healthcare*. Springer Nature.
- [Chu et al., 2022] Chu, J. N., Kaplan, C., Lee, J. S., Livaudais-Toman, J. e Karliner, L. (2022). Increasing telehealth access to care for older adults during the COVID-19 pandemic at an academic medical center: Video Visits for Elders Project (VVEP). *The Joint Commission Journal on Quality and Patient Safety*, 48(3):173–179.
- [Colón et al., 2014] Colón, L. N. V., DeLaHoz, Y. e Labrador, M. (2014). Human fall detection with smartphones. Em *2014 IEEE Latin-America Conference on Communications (LATINCOM)*, p. 1–7.
- [Conselho Federal de Medicina, 2022] Conselho Federal de Medicina (2022). Resolução cfm nº 2.314/2022. Acesso em: 03 04 2023.
- [Craig e Patterson, 2005] Craig, J. e Patterson, V. (2005). Introduction to the practice of telemedicine. *Journal of telemedicine and telecare*, 11:3–9.
- [da Silva et al., 2015] da Silva, L. N., da Silva, L. F., Goes, F. G. B., Machado, M. E. D. e Paiva, E. D. (2015). Orientações sobre quimioterapia junto à criança com câncer: método criativo sensível. *Online Brazilian Journal of Nursing*, 14(4):471–480.

- [Darkins et al., 2008] Darkins, A., Ryan, P., Kobb, R., Foster, L., Edmonson, E., Wakefield, B. e Lancaster, A. E. (2008). Care coordination/home telehealth: the systematic implementation of health informatics, home telehealth, and disease management to support the care of veteran patients with chronic conditions. *Telemedicine and e-Health*, 14(10):1118–1126.
- [de Campos Filho et al., 2022] de Campos Filho, A. S., Cursino, J. R. V., do Nascimento, J. W. A., de Souza, R. R., Roque, G. d. S. L. e de Souza Cavalcanti, A. R. (2022). Content and usability validation of an intelligent virtual conversation assistant used for virtual triage during the covid-19 pandemic in brazil. *CIN: Computers, Informatics, Nursing*, 40(11):779–785.
- [de Medeiros et al., 2022] de Medeiros, D. S. V., Mattos, D. M. F., Fernandes, N. C., de Aragão Rocha, A. A., de Albuquerque, C. V. N. e Muchaluat-Saade, D. C. (2022). *Challenges and future work directions in e-healthcare using blockchain technology*, p. 211–249. Healthcare Technologies. Institution of Engineering and Technology.
- [de Souza Filho et al., 2021] de Souza Filho, E., Fernandes, F., Wiefels, C., de Carvalho, L., Dos Santos, T., Dos Santos, A., Mesquita, E., Seixas, F., Chow, B., Mesquita, C. e Gismondi, R. (2021). Machine learning algorithms to distinguish myocardial perfusion spect polar maps. *Frontiers in Cardiovascular Medicine*, 8:741667.
- [Debnath et al., 2023] Debnath, P., Mahmud, A., Hossain, A. K. e Rahman, S. (2023). Design and application of iot-based real-time patient telemonitoring system using biomedical sensor network. *SN Computer Science*, 4(2):1–23.
- [Dinh et al., 2023] Dinh, A., Tseng, E., Yin, A. L., Estrin, D., Greenwald, P. e Fortenko, A. (2023). Perceptions about augmented reality in remote medical care: Interview study of emergency telemedicine providers. *JMIR Formative Research*, 7:e45211.
- [Ebihara et al., 2022] Ebihara, Y., Oki, E., Hirano, S., Takano, H., Ota, M., Morohashi, H., Hakamada, K., Urushidani, S. e Mori, M. (2022). Tele-assessment of bandwidth limitation for remote robotics surgery. *Surgery today*, 52(11):1653–1659.
- [Espinoza et al., 2020] Espinoza, J., Crown, K., Kulkarni, O. et al. (2020). A guide to chatbots for covid-19 screening at pediatric health care facilities. *JMIR public health and surveillance*, 6(2):e18808.
- [Fahmy, 2020] Fahmy, H. M. A. (2020). *Concepts, applications, experimentation and analysis of wireless sensor networks*. Springer Nature.
- [Ferreira et al., 2018] Ferreira, V. C., Caballero, E., Lima, R., Balbi, H., Seixas, F. L., Albuquerque, C. e Muchaluat-Saade, D. C. (2018). Redes corporais sem fio e suas aplicações em saúde. Em *Anais da 37ª JAI – Jornadas de Atualização em Informática*, chapter 4, p. 149–198. SBC, 1 ed.,o.
- [Fonseca et al., 2018] Fonseca, A. L. d. O., Fernandes, N. C., René Filho, P., Carrano, R. C. e Boechat, Y. E. (2018). Desenvolvendo uma solução de transmissão de mídias de baixo custo para o auxílio ao diagnóstico com imagens holográficas. Em *Anais da VI Escola Regional de Computação Aplicada à Saúde*. SBC.

- [Franco et al., 2022] Franco, G. A. S., Silva, L. F. d., Seixas, F. L., Góes, F. G. B., Pacheco, S. T. d. A. e Moraes, J. R. M. M. d. (2022). Químico em casa: Aplicativo para familiares de crianças e adolescentes em uso de antineoplásicos orais. *Texto & Contexto-Enfermagem*, 31.
- [Gagné e Franzen, 2023] Gagné, N. e Franzen, L. (2023). How to run behavioural experiments online: Best practice suggestions for cognitive psychology and neuroscience. *Swiss Psychology Open*, 3(1):5531.
- [Ganapathy et al., 2023] Ganapathy, S., Chang, S. Y. S., Tan, J. M. C., Lim, C. e Ng, K. C. (2023). Acute paediatrics tele-support for caregivers in singapore: an initial experience with a prototype chatbot: Upal. *Singapore Medical Journal*, 64(5):335.
- [Gilbert et al., 1997] Gilbert, C., Rahi, J., Eckstein, M., O’Sullivan, J. e Foster, A. (1997). Retinopathy of prematurity in middle-income countries. *The Lancet*, 350(9070):12–14.
- [Gillis et al., 2016] Gillis, J., Calyam, P., Apperson, O. e Ahmad, S. (2016). Panacea’s cloud: Augmented reality for mass casualty disaster incident triage and co-ordination. Em *2016 13th IEEE Annual Consumer Communications & Networking Conference (CCNC)*, p. 264–265.
- [Gonzalez et al., 2023] Gonzalez, G., Balakuntala, M., Agarwal, M., Low, T., Knoth, B., Kirkpatrick, A. W., McKee, J., Hager, G., Aggarwal, V., Xue, Y., Voyles, R. e Wachs, J. (2023). Asap: A semi-autonomous precise system for telesurgery during communication delays. *IEEE Transactions on Medical Robotics and Bionics*, 5(1):66–78.
- [Grazioli et al., 2023] Grazioli, S., Crippa, A., Rosi, E., Candelieri, A., Ceccarelli, S. B., Mauri, M., Manzoni, M., Mauri, V., Trabattoni, S., Molteni, M. et al. (2023). Exploring tediagnostic procedures in child neuropsychiatry: addressing adhd diagnosis and autism symptoms through supervised machine learning. *European child & adolescent psychiatry*, p. 1–11.
- [Gupta et al., 2019] Gupta, R., Tanwar, S., Tyagi, S. e Kumar, N. (2019). Tactile-internet-based telesurgery system for healthcare 4.0: An architecture, research challenges, and future directions. *IEEE Network*, 33(6):22–29.
- [Healthcare Information and Management Systems Society (HIMSS), 2020] Healthcare Information and Management Systems Society (HIMSS) (2020). Roundup: Tech’s role in tracking, testing, treating COVID-19. <https://www.mobihealthnews.com/news/roundup-techs-role-tracking-testing-treating-covid-19>. Acessado em Junho de 2023.
- [Hernandez et al., 2014] Hernandez, S. D., DeLaHoz, Y. e Labrador, M. (2014). Dynamic background subtraction for fall detection system using a 2d camera. Em *2014 IEEE Latin-America Conference on Communications (LATINCOM)*, p. 1–6.
- [Ho e Hendi, 2018] Ho, J. Y. e Hendi, A. S. (2018). Recent trends in life expectancy across high income countries: retrospective observational study. *BMJ*, 362.

- [Iuchno e De Carvalho, 2019] Iuchno, C. W. e De Carvalho, G. P. (2019). Toxicidade e efeitos adversos decorrente do tratamento quimioterápico antineoplásico em pacientes pediátricos: revisão integrativa. *Ciência & Saúde*, 12(1):e30329–e30329.
- [Iyer et al., 2022] Iyer, R., Nedeljkovic, M. e Meyer, D. (2022). Using voice biomarkers to classify suicide risk in adult telehealth callers: Retrospective observational study. *JMIR Ment Health*, 9(8):e39807.
- [Jackson-Triche e Mangurian, 2022] Jackson-Triche, M. e Mangurian, C. (2022). A covid-19 rapid mental health response for medical center health care workers. *Psychiatric Services*, 73(8):958–959.
- [Jackson-Triche et al., 2023] Jackson-Triche, M., Vetel, D., Turner, E.-M., Dahiya, P. e Mangurian, C. (2023). Meeting the behavioral health needs of health care workers during covid-19 by leveraging chatbot technology. *Journal of medical Internet research*.
- [John et al., 2022] John, O., Sarbadhikari, S. N., Prabhu, T., Goel, A., Thomas, A., Shroff, S., Allaudin, F., Weerabaddana, C., Alhuwail, D., Koirala, U., Johnrose, J., Codyre, P., Bleaden, A., Singh, S. e Bajaj, S. (2022). Implementation and experiences of telehealth: Balancing policies with practice in countries of south asia, kuwait, and the european union. *Interact J Med Res*, 11(1):e30755.
- [Kim et al., 2021] Kim, Y. J., DeLisa, J. A., Chung, Y.-C., Shapiro, N. L., Kolar Rajanna, S. K., Barbour, E., Loeb, J. A., Turner, J., Daley, S., Skowlund, J. e Krishnan, J. A. (2021). Recruitment in a research study via chatbot versus telephone outreach: a randomized trial at a minority-serving institution. *Journal of the American Medical Informatics Association*, 29(1):149–154.
- [Kobeissi e Ruppert, 2022] Kobeissi, M. M. e Ruppert, S. D. (2022). Remote patient triage: Shifting toward safer telehealth practice. *Journal of the American Association of Nurse Practitioners*, 34(3):444.
- [Lalonde, 2012] Lalonde, F. (2012). Guidelines for cardiac rehabilitation and secondary prevention programs. *Journal of Osteopathic Medicine*, 112(11):753–754.
- [Latifi et al., 2020] Latifi, R., Doarn, C. R. e Merrell, R. C. (2020). *Telemedicine, telehealth and telepresence: Principles, strategies, applications, and new directions*. Springer Nature.
- [Lau e McAlister, 2021] Lau, D. e McAlister, F. A. (2021). Implications of the COVID-19 pandemic for cardiovascular disease and risk-factor management. *Canadian Journal of Cardiology*, 37(5):722–732.
- [Letchumanan et al., 2020] Letchumanan, I., Gopinath, S. C. B., Md Arshad, M. K., Mohamed Saheed, M. S., Perumal, V., Voon, C. H. e Hashim, U. (2020). Gold-nanohybrid biosensors for analyzing blood circulating clinical biomacromolecules: Current trend toward future remote digital monitoring. *Critical Reviews in Analytical Chemistry*, p. 1–16.

- [Lin e Lue, 2023] Lin, G. e Lue, T. F. (2023). Revolutionizing laparoscopic telesurgery: The emergence of 5g-assisted wireless endoscopy systems. *Current Urology*, 17(2):82–83.
- [Lisboa et al., 2023] Lisboa, K. O., Hajjar, A. C., Sarmiento, I. P., Sarmiento, R. P. e Gonçalves, S. H. R. (2023). A história da telemedicina no brasil: desafios e vantagens. *Saúde e Sociedade*, 32.
- [López-Azor et al., 2022] López-Azor, J. C., de la Torre, N., Carmena, M. D. G.-C., Pérez, P. C., Munera, C., MarcoClement, I., León, R. C., Álvarez-García, J., Pachón, M., Ynsaurriaga, F. A. et al. (2022). Clinical utility of heartlogic, a multiparametric telemonitoring system, in heart failure. *Cardiac Failure Review*, 8.
- [Maldonado et al., 2016] Maldonado, J. M. S. d. V., Marques, A. B. e Cruz, A. (2016). Telemedicina: desafios à sua difusão no brasil. *Cadernos de Saúde Pública*, 32.
- [Marescaux et al., 2001] Marescaux, J., Leroy, J., Gagner, M., Rubino, F., Mutter, D., Vix, M., Butner, S. E. e Smith, M. K. (2001). Transatlantic robot-assisted telesurgery. *Nature*, 413(6854):379–380.
- [Maria et al., 2023] Maria, S., Mentis, H. M., Canlorbe, G. e Avellino, I. (2023). Supporting collaborative discussions in surgical teleconsulting through augmented reality head mounted displays. Em *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems*, p. 1–13.
- [Mastaneh e Mouseli, 2020] Mastaneh, Z. e Mouseli, A. (2020). Technology and its solutions in the era of covid-19 crisis: A review of literature. *Evidence Based Health Policy, Management and Economics*.
- [Mehta et al., 2021] Mehta, V., Dhall, A., Pal, S. e Khan, S. S. (2021). Motion and region aware adversarial learning for fall detection with thermal imaging. Em *2020 25th International Conference on Pattern Recognition (ICPR)*, p. 6321–6328.
- [Mesquita et al., 2018] Mesquita, J. L., Arruda, C. A. M. e de Macêdo, A. F. (2018). Perfil dos pacientes em terapia antineoplásica oral em um centro oncológico. *Cadernos ESP*, 12(1):46–56.
- [Messina et al., 2014] Messina, L. A., Filho, J. L. R. e de Lima Lopes, P. R., editors (2014). *RUTE 100 : as 100 primeiras unidades de telemedicina no Brasil e o impacto da Rede Universitária de Telemedicina (RUTE)*. E-papers, Rio de Janeiro.
- [Miller et al., 2018] Miller, A. C., Singh, I., Koehler, E. e Polgreen, P. M. (2018). A smartphone-driven thermometer application for real-time population-and individual-level influenza surveillance. *Clinical Infectious Diseases*, 67(3):388–397.
- [Miller et al., 2021] Miller, M. J., Pak, S. S., Keller, D. R. e Barnes, D. E. (2021). Evaluation of pragmatic telehealth physical therapy implementation during the covid-19 pandemic. *Physical therapy*, 101(1):pzaa193.

- [Morse et al., 2020] Morse, K. E., Ostberg, N. P., Jones, V. G. e Chan, A. S. (2020). Use characteristics and triage acuity of a digital symptom checker in a large integrated health system: population-based descriptive study. *Journal of medical Internet research*, 22(11):e20549.
- [Nelson et al., 2022] Nelson, C. R., Gabbard, J. L., Moats, J. B. e Mehta, R. K. (2022). User-centered design and evaluation of artrts: an augmented reality triage tool suite for mass casualty incidents. Em *2022 IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*, p. 336–345.
- [Neto et al., 2023] Neto, F. C., Milan, A. A., Fernandes, N. C. e Guimarães, A. G. (2023). Aplicações críticas habilitadas pela tecnologia 5g: Oportunidades, tendências e desafios. Em *Minicursos do XLI Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, number 4, p. 1–50. SBC.
- [Oki et al., 2023] Oki, E., Ota, M., Nakanoko, T., Tanaka, Y., Toyota, S., Hu, Q., Nakaji, Y., Nakanishi, R., Ando, K., Kimura, Y. et al. (2023). Telesurgery and telesurgical support using a double-surgeon cockpit system allowing manipulation from two locations. *Surgical Endoscopy*, p. 1–8.
- [Omboni et al., 2022] Omboni, S., Padwal, R. S., Alessa, T., Benczúr, B., Green, B. B., Hubbard, I., Kario, K., Khan, N. A., Konradi, A., Logan, A. G. et al. (2022). The worldwide impact of telemedicine during covid-19: current evidence and recommendations for the future. *Connected health*, 1:7.
- [Özbilgin et al., 2023] Özbilgin, F., Kurnaz, Ç. e Aydın, E. (2023). Prediction of coronary artery disease using machine learning techniques with iris analysis. *Diagnostics*, 13(6):1081.
- [Pagano et al., 2021] Pagano, C. G. M., de Campos Moreira, T., Sganzerla, D., Matzenbacher, A. M. F., Faria, A. G., Matturro, L., Cabral, F. C., Rucks Varvaki Rados, D., Decavata Szortyka, A., Falavigna, M., Vinadé Chagas, M. E., Harzheim, E., Gonçalves, M., Umpierre, R. e Lutz de Araujo, A. (2021). Teaming-up nurses with ophthalmologists to expand the reach of eye care in a middle-income country: Validation of health data acquisition by nursing staff in a telemedicine strategy. *PLoS One*, 16(11):e0260594.
- [Palumbo, 2022] Palumbo, A. (2022). Microsoft hololens 2 in medical and healthcare context: state of the art and future prospects. *Sensors*, 22(20):7709.
- [Park et al., 2022] Park, C., Cho, Y., Harvey, J., Arnoldo, B. e Levi, B. (2022). Telehealth and burn care: From faxes to augmented reality. *Bioengineering*, 9(5).
- [Pires et al., 2022] Pires, G., Lopes, A., Correia, P., Almeida, L., Oliveira, L., Panda, R., Jorge, D., Mendes, D., Dias, P., Gomes, N. e Pereira, T. (2022). Usability of a telehealth solution based on tv interaction for the elderly: the VITASENIOR-MT case study. *Universal Access in the Information Society*.

- [Prathiba e Rema, 2011] Prathiba, V. e Rema, M. (2011). Teleophthalmology: a model for eye care delivery in rural and underserved areas of india. *International journal of family medicine*, 2011.
- [Qazi et al., 2019] Qazi, S., Tanveer, K., ElBahnasy, K. e Raza, K. (2019). Chapter 10 - from telediagnosis to teletreatment: The role of computational biology and bioinformatics in tele-based healthcare. Em D. Jude, H. e Balas, V. E., editors, *Telemedicine Technologies*, p. 153–169. Academic Press.
- [Quigley et al., 2012] Quigley, P. A., Campbell, R. R., Bulat, T., Olney, R. L., Buerhaus, P. e Needleman, J. (2012). Incidence and cost of serious fall-related injuries in nursing homes. *Clinical Nursing Research*, 21(1):10–23.
- [Rae Nelson et al., 2022] Rae Nelson, C., Conwell, J., Lally, S., Cohn, M., Tanous, K., Moats, J. e Gabbard, J. L. (2022). Exploring augmented reality triage tools to support mass casualty incidents. Em *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, volume 66, p. 1664–1666. SAGE Publications Sage CA: Los Angeles, CA.
- [Ramalho et al., 2022] Ramalho, D., Constantino, P., Silva, H. P. D., Constante, M. e Sanches, J. (2022). An augmented teleconsultation platform for depressive disorders. *IEEE Access*, 10:130563–130571.
- [Reid et al., 2020] Reid, V., Hurst, T. et al. (2020). Q&a: Why providence health wants you to use its covid-19 triage chatbot. *Advisory Board: IT Forefront*.
- [Restás et al., 2021] Restás, Á., Szalkai, I. e Óvári, G. (2021). Drone application for spraying disinfection liquid fighting against the covid-19 pandemic—examining drone-related parameters influencing effectiveness. *Drones*, 5(3):58.
- [Rezende et al., 2010] Rezende, E. J. C., Melo, M. d. C. B. d., Tavares, E. C., Santos, A. d. F. d. e Souza, C. d. (2010). Ética e telessaúde: reflexões para uma prática segura. *Revista Panamericana de Salud Pública*, 28:58–65.
- [Robles Cuevas et al., 2022] Robles Cuevas, M. A., López Martínez, I., López Domínguez, E., Hernández Velázquez, Y., Domínguez Isidro, S., Flores Frías, L. M., Pomares Hernández, S. E., Medina Nieto, M. A. e de la Calleja, J. (2022). Telemonitoring system oriented towards high-risk pregnant women. Em *Healthcare*, volume 10, p. 2484. Multidisciplinary Digital Publishing Institute.
- [Rodgers et al., 2015] Rodgers, M. M., Pai, V. M. e Conroy, R. S. (2015). Recent advances in wearable sensors for health monitoring. *IEEE Sensors Journal*, 15(6):3119–3126.
- [Romero et al., 2023] Romero, S. E., Guevara, N., Montoya, X. e Castaneda, B. (2023). Assessment of panoramic ultrasound reconstruction imaging using telemedicine equipment: a phantom experiment. Em *18th International Symposium on Medical Information Processing and Analysis*, volume 12567, p. 269–276. SPIE.

- [Ruaro e Rodriguez, 2017] Ruaro, R. L. e Rodriguez, D. P. (2017). O direito À proteção de dados pessoais na sociedade da informação. *Revista de Direito da Economia e dos Sistemas de Informação*, 9(2):337–356.
- [Ruiz Estrada, 2020] Ruiz Estrada, M. A. (2020). The uses of drones in case of massive epidemics contagious diseases relief humanitarian aid: Wuhan-covid-19 crisis. *Available at SSRN 3546547*.
- [Russell et al., 2022] Russell, M. R., Rogers, R. L., Rosenthal, S. M. e Lee, J. Y. (2022). Increasing access to care for transgender/gender diverse youth using telehealth: A quality improvement project. *Telemedicine and e-Health*, 28(6):847–857.
- [Salman et al., 2021] Salman, O. H., Taha, Z., Alsabab, M. Q., Hussein, Y. S., Mohammed, A. S. e Aal-Nouman, M. (2021). A review on utilizing machine learning technology in the fields of electronic emergency triage and patient priority systems in telemedicine: Coherent taxonomy, motivations, open research challenges and recommendations for intelligent future work. *Computer Methods and Programs in Biomedicine*, 209:106357.
- [Santos et al., 2022] Santos, A., Seixas, F. e Fernandes, N. (2022). Provendo um modelo automático de detecção de quedas baseado em rede adversária generativa para assistência de idosos. Em *Anais do XXII Simpósio Brasileiro de Computação Aplicada à Saúde*, p. 120–131, Porto Alegre, RS, Brasil. SBC.
- [Santos et al., 2020a] Santos, A. C. N., Firmino, R. M., Soto, J. C. H., Medeiros, D. S. V., Mattos, D. M. F., Albuquerque, C. V. N., Seixas, F., Muchaluat-Saade, D. C. e Fernandes, N. C. (2020a). Aplicações em redes de sensores na área da saúde e gerenciamento de dados médicos: tecnologias em ascensão. Em Muchaluat-Saade, D. C. e Pita, R., editors, *Livro de Minicursos SBCAS 2020*, chapter 4, p. 1–50. SBC, 1 ed. o.
- [Santos et al., 2020b] Santos, W. S., de Sousa Júnior, J. H., Soares, J. C. e Raasch, M. (2020b). Reflexões acerca do uso da telemedicina no brasil: oportunidade ou ameaça? *Revista de Gestão em Sistemas de Saúde*, 9(3):433–453.
- [Scalvini et al., 2004] Scalvini, S., Vitacca, M., Paletta, L., Giordano, A. e Balbi, B. (2004). Telemedicine: a new frontier for effective healthcare services. *Monaldi Archives for chest disease*, 61(4).
- [Schieltz et al., 2022] Schieltz, K. M., O'Brien, M. J., Tsami, L., Call, N. A. e Lerman, D. C. (2022). Behavioral assessment and treatment via telehealth for children with autism: From local to global clinical applications. *International Journal of Environmental Research and Public Health*, 19(4).
- [Seixas et al., 2021] Seixas, F., Chermont, S., Marchese, L., Cruz, F. e Cruz, D. (2021). Monitoramento remoto da adesão dos pacientes em tratamento aos exercícios cardiorrespiratórios. *Catálogo de Tecnologias Sociais 2021*, UFF.

- [Seron et al., 2021] Seron, P., Oliveros, M.-J., Gutierrez-Arias, R., Fuentes-Aspe, R., Torres-Castro, R. C., Merino-Osorio, C., Nahuelhual, P., Inostroza, J., Jalil, Y., Solano, R. et al. (2021). Effectiveness of telerehabilitation in physical therapy: a rapid overview. *Physical therapy*, 101(6):pzab053.
- [Shah et al., 2016] Shah, P. K., Prabhu, V., Karandikar, S. S., Ranjan, R., Narendran, V. e Kalpana, N. (2016). Retinopathy of prematurity: Past, present and future. *World journal of clinical pediatrics*, 5(1):35.
- [Shoemaker et al., 2020] Shoemaker, M. J., Dias, K. J., Lefebvre, K. M., Heick, J. D. e Collins, S. M. (2020). Physical therapist clinical practice guideline for the management of individuals with heart failure. *Physical therapy*, 100(1):14–43.
- [Siddiqi e PiuZZi, 2021] Siddiqi, A. e PiuZZi, N. S. (2021). Value-based healthcare: Not going anywhere—why orthopaedic surgeons will continue using telehealth in a post-covid-19 world. *Clinical Orthopaedics and Related Research*, 479(6):1398.
- [Silva e Moraes, 2012] Silva, A. B. e Moraes, I. H. S. d. (2012). O caso da rede universitária de telemedicina: análise da entrada da telessaúde na agenda política brasileira. *Physis: Revista de Saúde Coletiva*, 22:1211–1235.
- [Song et al., 2022] Song, T., Yu, K., Eck, U. e Navab, N. (2022). Augmented reality collaborative medical displays (arc-meds) for multi-user surgical planning and intra-operative communication. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, p. 1–8.
- [Soto et al., 2022a] Soto, J. C., Galdino, I., Caballero, E., Ferreira, V., Muchaluat-Saade, D. e Albuquerque, C. (2022a). Monitoramento de sinais vitais utilizando redes wi-fi. Em Campista, M. e Duarte, F., editors, *Livro de Minicursos do SBRC 2022*, chapter 5. SBC, 1 edição.
- [Soto et al., 2022b] Soto, J. C., Galdino, I., Caballero, E., Ferreira, V., Muchaluat-Saade, D. e Albuquerque, C. (2022b). A survey on vital signs monitoring based on Wi-Fi CSI data. *Computer Communications*, 195:99–110.
- [Sterbis et al., 2008] Sterbis, J. R., Hanly, E. J., Herman, B. C., Marohn, M. R., Broderick, T. J., Shih, S. P., Harnett, B., Doarn, C. e Schenkman, N. S. (2008). Transcontinental telesurgical nephrectomy using the da vinci robot in a porcine model. *Urology*, 71(5):971–973.
- [Su et al., 2023] Su, T., Calvo, R. A., Jouaiti, M., Daniels, S., Kirby, P., Dijk, D.-J., della Monica, C. e Vaidyanathan, R. (2023). Assessing a sleep interviewing chatbot to improve subjective and objective sleep: Protocol for an observational feasibility study. *JMIR Res Protoc*, 12:e45752.
- [Tan et al., 2022] Tan, T. F., Li, Y., Lim, J. S., Gunasekeran, D. V., Teo, Z. L., Ng, W. Y. e Ting, D. S. (2022). Metaverse and virtual health care in ophthalmology: opportunities and challenges. *The Asia-Pacific Journal of Ophthalmology*, 11(3):237–246.

- [Tsumura et al., 2021] Tsumura, R., Hardin, J. W., Bimbraw, K., Grossestreuer, A. V., Odusanya, O. S., Zheng, Y., Hill, J. C., Hoffmann, B., Soboyejo, W. e Zhang, H. K. (2021). Tele-operative low-cost robotic lung ultrasound scanning platform for triage of covid-19 patients. *IEEE Robotics and Automation Letters*, 6(3):4664–4671.
- [Vestergaard e Wulf, 2020] Vestergaard, T. B. e Wulf, H. C. (2020). Accuracy of mobile digital teledermoscopy for skin self-examinations in adults at high risk of skin cancer: an open-label, randomised controlled trial. *The Lancet Digital Health*, 2(4):e175–e182.
- [von Stillfried, 2021] von Stillfried, D. G. (2021). Toward a digital triage platform for the german healthcare system. *Mission–Innovation: Telematics, eHealth and High-Definition Medicine in Patient-Centered Acute Medicine*, p. 121.
- [Wen, 2008] Wen, C. L. (2008). Telemedicina e telessaúde: um panorama no brasil. *Informática Pública*, 10(2):7–15.
- [William et al., 2018] William, W., Ware, A., Basaza-Ejiri, A. H. e Obungoloch, J. (2018). A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images. *Computer methods and programs in biomedicine*, 164:15–22.
- [Williams et al., 2018] Williams, A. M., Bhatti, U. F., Alam, H. B. e Nikolian, V. C. (2018). The role of telemedicine in postoperative care. *Mhealth*, 4.
- [World Health Organization, 2022] World Health Organization (2022). *Consolidated telemedicine implementation guide*. WHO, Geneva.
- [Xu et al., 2020] Xu, Q., Huang, G., Yu, M. e Guo, Y. (2020). Fall prediction based on key points of human bones. *Physica A: Statistical Mechanics and its Applications*, 540(C).
- [Young et al., 2023] Young, B. K., Cole, E. D., Shah, P. K., Ostmo, S., Subramaniam, P., Venkatapathy, N., Tsai, A. S. H., Coyner, A. S., Gupta, A., Singh, P., Chiang, M. F., Kalpathy-Cramer, J., Chan, R. V. P. e Campbell, J. P. (2023). Efficacy of Smartphone-Based Telescreening for Retinopathy of Prematurity With and Without Artificial Intelligence in India. *JAMA Ophthalmology*.
- [Zhang et al., 2022] Zhang, J., Yu, N., Wang, B. e Lv, X. (2022). Trends in the use of augmented reality, virtual reality, and mixed reality in surgical research: A global bibliometric and visualized analysis. *Indian Journal of Surgery*, 84(Suppl 1):52–69.
- [Ziebart et al., 2023] Ziebart, C., Kfrerer, M. L., Stanley, M. e Austin, L. C. (2023). A digital-first health care approach to managing pandemics: Scoping review of pandemic self-triage tools. *J Med Internet Res*, 25:e40983.