

## Capítulo

# 3

## Indústria 5.0: Implementando Sistemas de Decisão Orientados por Dados.

Júlio V. M. Marques, Clésio A. Gonçalves, Armando L. Borges, Viviane B. Leal Dias, Willians S. Santos e Romuere R. V. Silva

### *Abstract*

*The transition from Industry 4.0 to Industry 5.0 highlights the importance of reintegrating humans into production processes, fostering collaboration between humans and machines. Personalization and sustainability become essential, with data-driven decision systems playing a key role. This work explores the implementation of these systems, from data preparation to integration in industrial environments, demonstrating their capacity to transform operations and maximize efficiency. It also discusses the challenges and opportunities of Industry 5.0, emphasizing the need for continuous innovation, ethics, and organizational adaptation to ensure success in the new industrial era.*

### *Resumo*

*A transição da Indústria 4.0 para a Indústria 5.0 destaca a importância de reintegrar o ser humano nos processos produtivos, promovendo colaboração entre humanos e máquinas. A personalização e a sustentabilidade tornam-se essenciais, com sistemas de decisão baseados em dados desempenhando um papel importante. Este trabalho explora a implementação desses sistemas, desde a preparação de dados até a integração em ambientes industriais, evidenciando sua capacidade de transformar operações e maximizar a eficiência. Também discute os desafios e as oportunidades da Indústria 5.0, enfatizando a necessidade de inovação contínua, ética e adaptação organizacional para garantir o sucesso na nova era industrial.*

### **1.1. Introdução**

A Revolução Industrial, em cada uma de suas fases, trouxe mudanças profundas na forma como as sociedades produzem e consomem bens e serviços. A Indústria 4.0, com seus avanços tecnológicos centrados na automação, conectividade e digitalização, abriu um

novo capítulo nessa evolução [1]. Esse período foi marcado por uma automação em larga escala, resultando em ganhos significativos de produtividade e redução de custos. Tecnologias que permitiram a produção em massa de forma flexível foram desenvolvidas, possibilitando que máquinas operassem de maneira autônoma, sem a constante necessidade de intervenção humana [2]. Contudo, esse progresso também suscitou preocupações acerca da desumanização dos processos produtivos e da potencial perda de empregos qualificados, à medida que a dependência de máquinas e algoritmos aumentava. Além disso, surgiram questões relacionadas à sustentabilidade ambiental, destacando a importância de equilibrar o uso da tecnologia com a preservação dos valores humanos e do meio ambiente.

Em resposta aos desafios apresentados pela Indústria 4.0, a Indústria 5.0 emerge com o propósito de reintegrar o ser humano nos processos produtivos, promovendo um ambiente de trabalho mais colaborativo, sustentável e personalizado [3]. Diferentemente da Indústria 4.0, que enfatiza a automação e a eficiência, a Indústria 5.0 valoriza a colaboração entre humanos e máquinas [4]. Essa nova fase industrial visa combinar o poder da tecnologia com a criatividade e a adaptabilidade humanas, criando produtos e serviços que atendem às necessidades específicas dos clientes, com uma ênfase especial em sustentabilidade e ética [5]. A coleta e análise de grandes volumes de dados permitem a personalização dos processos produtivos, enquanto a inteligência artificial apoia os trabalhadores na realização de tarefas complexas. Ademais, a Indústria 5.0 promove a economia circular e o uso de materiais reciclados, reduzindo assim o impacto ambiental.

A transição da Indústria 4.0 para a Indústria 5.0 oferece às empresas não apenas a oportunidade de aprimorar sua competitividade e resiliência, mas também impõe uma reestruturação significativa que abrange tanto aspectos tecnológicos quanto culturais. Este capítulo se propõe a explorar profundamente os conceitos centrais da Indústria 5.0, destacando suas diferenças em relação à Indústria 4.0, além dos principais desafios e oportunidades que surgem com sua adoção. A análise busca fornecer *insights* valiosos para que as empresas adaptem suas operações a essa nova era, aproveitando os avanços tecnológicos sem negligenciar a importância do toque humano. O objetivo final é demonstrar como as organizações podem integrar harmoniosamente inovação tecnológica e personalização, garantindo que a evolução industrial se alinhe com a sustentabilidade e as necessidades humanas.

Este trabalho está estruturado da seguinte forma: a Seção 1.2 explora os fundamentos dos sistemas de decisão baseados em dados; a Seção 1.3 discute a implementação dos sistemas de decisão na indústria 5.0; a Seção 1.4 aborda as vantagens da decisão orientada por dados; a Seção 1.5 apresenta os desafios e barreiras na implementação desses sistemas; a Seção 1.6 explora o futuro dos sistemas de decisão na indústria 5.0; a Seção 1.7 demonstra um estudo de caso e suas principais etapas, por fim, a Seção 1.8 oferece os principais *insights* e conclusões.

## **1.2. Fundamentos dos Sistemas de Decisão Baseados em Dados**

Com o advento da Indústria 5.0, uma nova dimensão se estabelece na interação entre humanos e máquinas, onde a personalização e a tomada de decisões em tempo real tornam-se elementos centrais dos processos produtivos [6]. Nesse cenário, os sistemas de decisão

baseados em dados emergem como ferramentas indispensáveis para alinhar a capacidade analítica das máquinas com a intuição e o conhecimento humano. Esses sistemas processam grandes volumes de dados, fornecendo informações precisas que permitem às organizações responder rapidamente a mudanças, minimizar riscos potenciais, maximizar oportunidades e otimizar processos internos.

Os sistemas de decisão baseados em dados são uma forma de Sistemas de Apoio à Decisão (SAD). Esses SADs são modelos computacionais projetados para analisar grandes volumes de dados, auxiliando seus usuários na tomada de decisões dentro de um contexto específico [7]. Esses sistemas são particularmente valiosos no ambiente empresarial, onde a precisão na análise de variáveis voláteis e em cenários dinâmicos é crucial. A análise correta e precisa dessas variáveis pode ser o fator decisivo para o sucesso das ações implementadas.

Dada a sua relevância, é importante destacar que os SADs são capazes de resolver problemas pouco ou não-estruturados. Em outras palavras, eles são capazes de lidar com situações onde as variáveis e os critérios para a tomada de decisão não estão claramente definidos, são incertos ou até mesmo implícitos. A função dos SADs é auxiliar os tomadores de decisão na exploração de diferentes alternativas e na avaliação dos possíveis impactos de suas escolhas. Devido à sua grande capacidade, esses sistemas são amplamente utilizados no nível estratégico da pirâmide organizacional [8]. A habilidade dos SADs de compilar grandes volumes de dados e de sintetizar essa informação de maneira organizada e acessível para gestores e analistas os torna eficazes na execução de atividades como o planejamento estratégico, o controle gerencial e operacional. A Figura 1.1 ilustra a abrangência dos SADs na pirâmide organizacional.



Figura 1.1: A pirâmide organizacional demonstra que, embora os SADs sejam amplamente aplicados no nível estratégico, eles também podem ser utilizados para apoiar os outros níveis da organização.

Como ilustrado na Figura 1.1, os SADs podem ser aplicados em todos os três ní-

veis da pirâmide organizacional. No nível operacional, onde atividades rotineiras garantem o funcionamento contínuo da organização, os SADs são empregados para automatizar e otimizar processos, como controle de produção, gestão de inventário e monitoramento de desempenho, garantindo agilidade na resolução de questões ou problemas decisórios [9]. No nível tático, que se concentra em planos e decisões de médio prazo, os SADs fornecem análises detalhadas e previsões de cenários futuros [10], auxiliando gestores a alinhar as operações diárias com os objetivos estratégicos da empresa e a otimizar o uso de recursos. Finalmente, no nível estratégico, onde são tomadas decisões de longo prazo que impactam toda a organização, os SADs oferecem suporte essencial aos executivos, proporcionando análises aprofundadas, simulações de cenários e ferramentas de previsão que permitem aos líderes avaliar riscos e identificar oportunidades potenciais [11].

Nesse contexto, os sistemas de decisão baseados em dados são uma forma de SADs que se concentram na utilização de grandes volumes de dados e técnicas analíticas avançadas para apoiar a tomada de decisões. Esses sistemas priorizam o uso de quantidades significativas de dados em conjunto com técnicas de aprendizado de máquina e outros métodos analíticos para descobrir padrões e tendências. Além disso, eles são capazes de automatizar partes do processo decisório, fornecendo recomendações ou ações sugeridas com base na análise de dados em tempo real.

### **1.2.1. Componentes principais**

De acordo com Power [12], em sua obra intitulada *Decision Support Systems: Concepts and Resources for Managers*, os SADs são compostos por quatro componentes principais: banco de dados, modelos, comunicação e interface com o usuário. A Figura 1.2 apresenta um diagrama que ilustra como esses componentes se interligam e formam um Sistema de Apoio à Decisão.

O componente de banco de dados é responsável por armazenar e gerenciar todos os dados necessários para fundamentar a tomada de decisões. Em essência, sua função principal é alocar todos os dados, documentos e informações que servirão como base para os modelos analíticos [12]. Esse componente pode incluir bancos de dados relacionais, *data warehouses*, *data marts*, entre outras formas de armazenamento de dados. Nesse contexto, a qualidade e a acessibilidade dos dados são cruciais para o sucesso das análises.

O componente de modelo abrange os modelos analíticos e matemáticos responsáveis pelo processamento dos dados [12]. Nesse componente estão incluídos algoritmos para análises estatísticas, simulações, aprendizado de máquina e inteligência artificial. Esses algoritmos transformam os dados brutos em informações úteis para apoiar o processo decisório, identificando até mesmo pequenas nuances que podem ter um impacto significativo na decisão final. Por meio de simulações e análises, os modelos podem destacar a melhor solução dentre as disponíveis, com base em parâmetros pré-estabelecidos, e até realizar previsões sobre cenários futuros.

O componente de comunicação, como o próprio nome indica, é responsável por mediar e assegurar a troca de dados e informações entre os diversos componentes internos do SAD, bem como com sistemas externos [12]. Sua estrutura inclui protocolos, redes de comunicação, APIs e ferramentas que facilitam um processo de comunicação eficiente. Esse componente atua como uma ponte, conectando todos os elementos do SAD e permi-

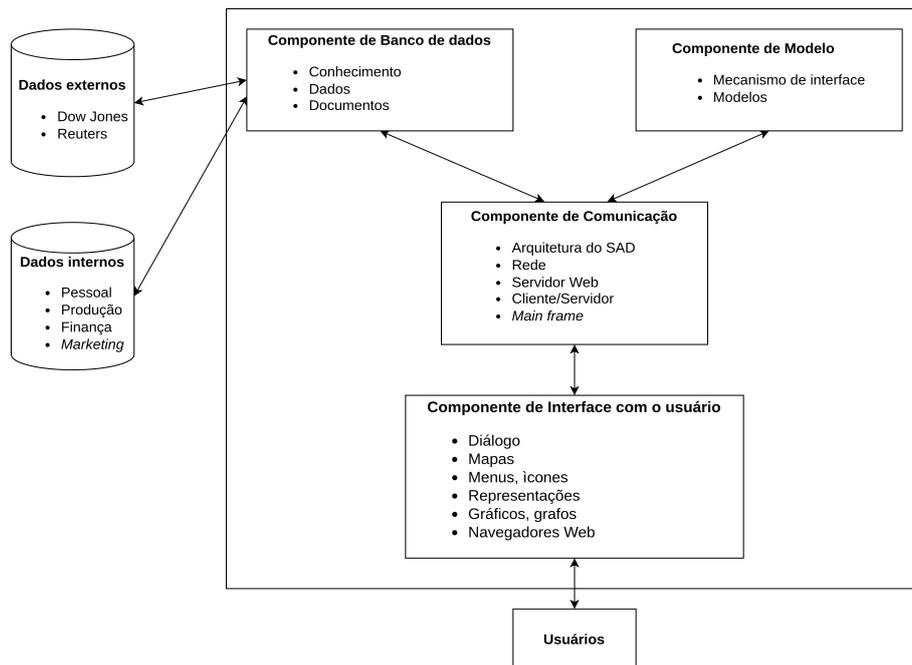


Figura 1.2: Diagrama dos componentes de um SAD, conforme descrito por Power [12]. Imagem adaptada do livro *Decision Support Systems: Concepts and Resources for Managers*.

tindo que interajam de forma contínua. Além disso, ele possibilita que diferentes usuários e partes interessadas participem do processo decisório e de análise.

O quarto componente é a interface com o usuário, que serve como o ponto de contato entre os indivíduos e o SAD. Através desse componente, os usuários podem visualizar os resultados das análises processadas pelos modelo [12]. Ele define como os usuários interagem com o sistema, por meio de uma interface bem projetada e adaptada às suas necessidades. Com essa interface, os usuários podem se comunicar com o sistema, visualizando informações processadas, realizando consultas, explorando dados e ajustando parâmetros. Essas funcionalidades permitem investigar possíveis cenários e soluções alternativas para questões ou problemas específicos, levando a conclusões fundamentadas no processo decisório.

### 1.2.2. Técnicas Analíticas

Conforme mencionado anteriormente, uma variedade de algoritmos e técnicas pode ser utilizada para processar dados brutos, com o objetivo de extrair *insights* relevantes para a tomada de decisões. A análise estatística é uma das abordagens fundamentais para a obtenção de informações a partir de um conjunto de dados [13]. Esse processo envolve uma série de cálculos e métodos descritivos, como testes de hipóteses, análise de regressão, análise de séries temporais e análise de variância, que permitem identificar padrões, tendências, correlações e outras características importantes nos dados.

Outra técnica amplamente utilizada devido à sua capacidade de avançar rapidamente e produzir resultados precisos é o uso de algoritmos de aprendizado de máquina e

inteligência artificial. Esses algoritmos permitem que computadores identifiquem e interpretem padrões a partir de conjuntos de dados [14]. Nesse contexto, é importante destacar que existem algoritmos supervisionados, onde o conjunto de dados deve ser rotulado para que o modelo aprenda com base na diferença entre suas inferências e os rótulos fornecidos. Por outro lado, os algoritmos não supervisionados não requerem rótulos, sendo capazes de identificar padrões sem orientação explícita sobre o resultado esperado. Além disso, existem os algoritmos de aprendizado por reforço, nos quais um agente aprende a tomar decisões ao interagir com um ambiente, recebendo recompensas ou penalidades com base em suas ações. Em geral, esses algoritmos podem melhorar suas previsões ou decisões ao longo do tempo, sem a necessidade de serem programados explicitamente para cada tarefa.

Nesse contexto, também é relevante mencionar a análise de simulação. Essa técnica envolve a criação de modelos que replicam o comportamento de um sistema real para prever o impacto de diferentes variáveis ou cenários. Isso permite que os tomadores de decisão testem diversas hipóteses e compreendam os possíveis resultados sem a necessidade de implementar mudanças no mundo real. Por meio desse método, é possível detalhar aspectos do modelo com base nos fatores que se deseja considerar [15]. Algumas técnicas comuns de simulação incluem a Simulação de Monte Carlo, que utiliza métodos estatísticos para modelar a probabilidade de diferentes resultados em processos que podem ser repetidos várias vezes, sendo frequentemente aplicada para prever incertezas em modelos financeiros ou de negócios. Além disso, é importante destacar a Simulação Discreta de Eventos, onde o valor ou estado de um ou mais fenômenos é alterado em pontos discretos no tempo [16]. Essa técnica é amplamente utilizada para modelar e otimizar linhas de produção, simulando o fluxo de materiais, tempos de processamento e gargalos.

### **1.3. Implementação de Sistemas de Decisão na Indústria 5.0**

A implementação de sistemas de decisão na Indústria 5.0 representa um avanço significativo ao combinar inteligência artificial com a criatividade humana, estabelecendo um novo paradigma de colaboração [17]. Nesse contexto, a parceria entre humanos e máquinas inteligentes resulta em um aumento substancial na eficiência e na personalização dos processos industriais. A fusão da precisão, velocidade e automação das máquinas com a intuição e o discernimento humano gera um sistema altamente adaptável e ágil. Esses sistemas facilitam a análise de dados em tempo real, permitindo que os processos de produção se adaptem às demandas do mercado e às necessidades individuais dos consumidores [18]. O desenvolvimento desses sistemas segue etapas definidas e utiliza tecnologias avançadas, sendo projetado para ser eficiente, sustentável e alinhado com os princípios de responsabilidade social e ambiental [19]. Cada sistema de decisão contribui de maneira distinta para a otimização dos processos industriais, oferecendo soluções específicas para diferentes desafios e promovendo uma gestão mais eficaz e flexível.

Os SADs são projetados para auxiliar gestores na análise de grandes volumes de dados provenientes de diversas fontes. Eles integram informações operacionais, financeiras e de mercado para criar relatórios e análises que apoiam decisões estratégicas e táticas. Por meio da modelagem matemática e da análise estatística, os SADs fornecem dados detalhados sobre diferentes cenários, facilitando a tomada de decisões mais informadas. A implementação de um SAD exige a integração de dados de sistemas existentes,

como os de gestão de recursos (ERP) e de relacionamento com clientes (CRM). Além disso, são desenvolvidos *dashboards* interativos que permitem explorar e entender os dados de forma visual e intuitiva. Esses *dashboards* asseguram a qualidade das informações e oferecem flexibilidade para atender às necessidades analíticas. Pesquisas indicam que os SADs melhoram a eficiência na tomada de decisões ao utilizarem ferramentas avançadas de análise e visualização de dados, permitindo uma interpretação mais clara de conjuntos complexos de informações [20]. Sua capacidade de adaptação a diferentes setores demonstra sua versatilidade e contribui para melhores resultados operacionais [21]. Existem diferentes categorias de sistemas de decisão, cada uma com características e finalidades específicas para otimizar processos em suas respectivas áreas de aplicação. Nos parágrafos seguintes, serão apresentados os principais sistemas de decisão, explorando suas funcionalidades básicas e como contribuem para a evolução da indústria moderna.

Os Sistemas de Informação Gerencial (SIG) são desenvolvidos para auxiliar as empresas na gestão e monitoramento de suas atividades diárias. Esses sistemas coletam e organizam informações detalhadas sobre o desempenho das operações da empresa, como produtividade e eficiência. A partir desses dados, os SIGs geram relatórios automatizados que ajudam os gestores a compreender o andamento das operações e a tomar decisões baseadas em dados. Para implementar um SIG de forma eficaz, é necessário configurar sistemas que possam coletar dados em tempo real, definir Indicadores-Chave de Desempenho (KPIs) que medem aspectos críticos das operações e desenvolver relatórios automatizados que apresentem essas informações de maneira clara e acessível. Além disso, o SIG deve integrar dados de diferentes departamentos para fornecer uma visão completa e integrada do desempenho da empresa. Em outras palavras, o SIG transforma dados operacionais em informações úteis e acionáveis, facilitando a gestão e a tomada de decisões, aumentando o valor comercial e a lucratividade por meio da utilização eficaz dos dados [22]. A integração eficiente dos dados e a clareza na apresentação das informações são essenciais para o sucesso desses sistemas.

Os Sistemas Especialistas são projetados para replicar o conhecimento e a experiência de especialistas humanos em áreas específicas, oferecendo recomendações fundamentadas em regras e conhecimento técnico especializado. Esses sistemas podem aumentar a eficiência operacional em até 42% e contribuem positivamente para o crescimento organizacional [23]. Os Sistemas Especialistas são particularmente valiosos na resolução de problemas que exigem um elevado nível de expertise técnica. Eles operam por meio de bases de conhecimento e inferência lógica, simulando o raciocínio dos especialistas. Esses sistemas aplicam regras de decisão codificadas para fornecer soluções a questões complexas. A implementação de Sistemas Especialistas envolve várias etapas, incluindo a captura e modelagem do conhecimento especializado, a codificação das regras de decisão e o treinamento do sistema com dados relevantes. Além disso, é essencial que esses sistemas sejam continuamente atualizados com novos conhecimentos e permitam interações com os usuários, a fim de aprimorar a precisão e a relevância das respostas fornecidas. Esse processo contínuo de atualização e interação garante que o sistema permaneça eficaz e alinhado com as necessidades dos usuários.

Sistemas Baseados em Inteligência Artificial (IA) utilizam algoritmos avançados para analisar grandes volumes de dados e gerar previsões ou recomendações. Esses sistemas têm a capacidade de aprender com os dados, aprimorando seu desempenho ao longo

do tempo, identificando padrões complexos e realizando previsões precisas com base em informações históricas e em tempo real, demonstrando sua capacidade de adaptação e melhoria contínua [24]. A implementação desses sistemas envolve etapas vitais. Primeiramente, é necessário desenvolver e treinar modelos utilizando dados históricos e atuais. Em seguida, esses modelos devem ser integrados aos processos existentes e disponibilizados por meio de interfaces de usuário adequadas. Para garantir que esses sistemas permaneçam precisos e relevantes, é essencial que os modelos sejam ajustados e atualizados regularmente. Esse processo contínuo de ajuste e monitoramento assegura que os sistemas de IA permaneçam eficazes e alinhados com as necessidades dos usuários.

Os Sistemas de Análise Preditiva utilizam técnicas de análise estatística e algoritmos de aprendizado de máquina para prever eventos futuros e identificar tendências com base em dados históricos e em tempo real. Esses sistemas permitem antecipar falhas, variações na demanda e outras variáveis críticas, possibilitando a adoção de ações preventivas e a otimização de processos [25]. A implementação desses sistemas envolve etapas essenciais, começando pela coleta e preparação dos dados históricos. Em seguida, é necessário desenvolver modelos preditivos que serão integrados aos sistemas de decisão, permitindo que as previsões sejam aplicadas de maneira prática. É fundamental que o sistema tenha a capacidade de lidar com variáveis em tempo real e ajustar suas previsões conforme necessário, garantindo a precisão e a relevância das análises. A adaptação e a atualização contínuas são vitais para assegurar que os sistemas de análise preditiva permaneçam eficazes e alinhados com as condições dinâmicas do ambiente operacional.

Os Sistemas de Gestão de Conhecimento (SGC) são projetados para capturar, organizar e compartilhar o conhecimento dentro de uma organização. Eles auxiliam na utilização tanto do conhecimento explícito quanto do tácito, aumentando a eficiência e promovendo a inovação. Os SGC criam bases de dados onde o conhecimento pode ser armazenado e acessado, facilitando a colaboração entre funcionários e permitindo o uso de informações acumuladas para resolver problemas e desenvolver novas ideias. A implementação de um SGC exige a construção de uma plataforma onde as informações possam ser armazenadas e compartilhadas de maneira fácil e intuitiva. Isso envolve o desenvolvimento de ferramentas de busca eficientes e o incentivo à participação dos colaboradores na contribuição de conhecimento. A facilidade de uso e o estímulo à colaboração são fundamentais para garantir que todos na organização possam usufruir ao máximo do sistema e contribuir para o compartilhamento de informações. Esses sistemas são vitais para aumentar a competitividade organizacional, simplificando a coleta, o processamento e a propagação do conhecimento, apoiando o aprendizado e desenvolvimento contínuos [26].

### **1.3.1. Estratégias para Implementação de Sistemas de Decisão na Indústria 5.0**

A implementação de sistemas de decisão na Indústria 5.0 exige um conjunto cuidadosamente planejado de estratégias organizadas em fases distintas, cada uma desempenhando um papel importante para o sucesso do sistema. Essas estratégias são fundamentais para assegurar que o sistema atenda às necessidades da organização e contribua para a eficiência e a inovação dos processos industriais. A Figura 1.3 apresenta visualmente as principais etapas necessárias para a implementação eficaz de um sistema de decisão.

O planejamento é a fase inicial e essencial na implementação de sistemas de de-



Figura 1.3: Etapas da implementação de um sistema de decisão.

ção. Nesta etapa, são definidos os objetivos do sistema, os requisitos de dados e as metas de desempenho. Um planejamento eficaz garante que o sistema de decisão esteja alinhado com as estratégias da organização e atenda tanto às necessidades operacionais quanto às estratégicas [27]. Durante essa fase, são identificadas as necessidades da organização, estabelecido o escopo do projeto, e definidos cronogramas e orçamentos. Esse planejamento fornece uma base sólida para todas as fases subsequentes [28], garantindo que o sistema esteja preparado para cumprir as expectativas e objetivos da organização.

A fase de desenvolvimento abrange a criação ou personalização do software de decisão, a configuração dos modelos de decisão e a integração com os sistemas existentes. É vital que o desenvolvimento leve em conta a flexibilidade e a escalabilidade do sistema, permitindo adaptações conforme as necessidades da organização evoluem. Nesta etapa, são realizadas atividades como a codificação do sistema, a integração de dados provenientes de diversas fontes e o desenvolvimento de interfaces de usuário que sejam intuitivas e funcionais. O alinhamento do desenvolvimento com as metas organizacionais influencia de forma positiva os resultados obtidos [29]. Um desenvolvimento bem-sucedido resulta em um sistema que atende aos requisitos atuais e é capaz de se adaptar a futuras mudanças e expansões.

Os testes são fundamentais para garantir que o sistema funcione conforme o esperado e atenda às especificações estabelecidas. Esta fase inclui a realização de simulações e

validações para avaliar o desempenho do sistema em situações reais. Os testes verificam a funcionalidade geral do sistema, seu desempenho em diferentes cenários e a necessidade de ajustes baseados nos resultados obtidos. A condução de testes rigorosos assegura que o sistema esteja pronto para operar de maneira eficiente no ambiente de produção [30].

O treinamento é uma etapa essencial para garantir que os usuários possam operar o sistema de decisão de maneira eficiente. Durante essa fase, são desenvolvidos manuais e materiais de apoio, realizados *workshops* e sessões práticas, além de ser oferecido suporte contínuo aos usuários. O objetivo é assegurar que os operadores se sintam confortáveis e capacitados ao utilizar o novo sistema [30]. Um treinamento eficaz não apenas facilita a adoção do sistema, mas também maximiza seu potencial, capacitando os usuários a explorar e compreender todas as funcionalidades com excelência.

A implementação envolve a introdução gradual do sistema no ambiente de produção. Essa fase deve ser planejada com cuidado para minimizar riscos e permitir ajustes conforme necessário. A implementação inclui a integração do sistema com os processos existentes, a adaptação dos operadores às novas ferramentas e a realização de ajustes durante a transição. Uma implementação bem planejada e executada garante uma integração suave e eficiente do sistema, minimizando a interrupção das operações diárias [31].

Após a implementação, se inicia a fase de monitoramento contínuo e manutenção. Essa etapa é vital para garantir que o sistema continue operando de maneira eficiente e se adapte às mudanças nas condições operacionais. O monitoramento envolve a observação constante do desempenho do sistema, a atualização dos modelos de decisão conforme necessário e a realização de ajustes para resolver quaisquer problemas que possam surgir [32]. A manutenção contínua assegura que o sistema permaneça relevante e eficaz ao longo do tempo, atendendo às necessidades em constante evolução da organização [28].

Essas estratégias são essenciais para a implementação bem-sucedida de sistemas de decisão. Elas fornecem uma base sólida para a tomada de decisões eficazes e para a otimização dos processos industriais, estabelecendo um novo padrão de eficiência e inovação no ambiente industrial moderno. A integração harmoniosa entre a inteligência artificial e a criatividade humana é o que define o sucesso dessas estratégias, permitindo que as organizações aproveitem ao máximo as vantagens oferecidas pela Indústria 5.0.

#### **1.4. Vantagens da Decisão Orientada por Dados**

A tomada de decisão baseada em dados é o processo de utilizar dados para orientar as decisões e validar o curso das ações. De acordo com uma pesquisa realizada pela PwC com mais de 1.000 executivos seniores, organizações altamente orientadas por dados têm três vezes mais probabilidade de relatar melhorias significativas na tomada de decisões em comparação àquelas que dependem menos de dados [33].

Decisões fundamentadas em dados permitem a otimização de processos e recursos, eliminando ineficiências. Isso resulta em maior produtividade ao automatizar tarefas repetitivas e concentrar esforços em áreas que geram maior valor. Ao utilizar dados coletados de clientes e mercados, as empresas podem desenvolver produtos e serviços altamente personalizados, atendendo às necessidades e preferências específicas dos clientes. Esse nível de personalização aumenta a satisfação e a fidelização do cliente.

Além disso, decisões baseadas em dados podem contribuir para monitorar e reduzir o desperdício, otimizar o uso de recursos e melhorar a sustentabilidade ambiental das operações, alinhando-se com as metas de responsabilidade corporativa.

### **1.5. Desafios e Barreiras**

Com a chegada da Indústria 5.0, é fácil subestimar os desafios que ela traz. No entanto, para que a Indústria 5.0 se traduza em sucesso para os negócios, é essencial que esses desafios sejam identificados e resolvidos de maneira eficaz.

A Indústria 5.0 requer transformações culturais significativas nas empresas, incluindo a adoção de novos modelos de gestão, a promoção de uma colaboração mais estreita entre equipes multidisciplinares, o aumento da demanda por profissionais altamente qualificados e a possível redução de postos de trabalho em determinadas áreas.

A coleta e o uso de grandes volumes de dados levantam preocupações substanciais em relação à segurança. Proteger esses dados contra violações e ataques cibernéticos, além de garantir a conformidade com regulamentos de privacidade, torna-se fundamental. Além disso, a integração e sincronização dos sistemas existentes com novos sistemas de coleta de dados apresentam um desafio considerável para o funcionamento eficiente da Indústria 5.0.

A transição para uma cultura orientada por dados pode enfrentar resistência dentro das organizações, seja devido ao medo de mudanças, à falta de habilidades digitais, ou a preocupações com a substituição do trabalho humano pela automação. A adoção de tecnologias avançadas exige um compromisso adicional de tempo e esforço por parte dos trabalhadores. Fábricas inteligentes, conectadas por software, inteligência artificial, informações em tempo real e a Internet das Coisas (IoT), são componentes essenciais para o sucesso da Indústria 5.0.

A implementação de sistemas de decisão orientados por dados pode demandar investimentos substanciais em tecnologia, infraestrutura e capacitação. Para muitas organizações, especialmente pequenas e médias empresas, o custo inicial pode representar uma barreira significativa.

### **1.6. O Futuro dos Sistemas de Decisão na Indústria 5.0**

A Indústria 5.0 representa uma mudança de foco, passando de uma abordagem puramente econômica para uma ênfase no valor social e no bem-estar. Ela abrange diversos processos, não se limitando apenas à fabricação, e é viabilizada por avanços tecnológicos, incluindo inteligência artificial, automação, dados, Internet das Coisas e aprendizado de máquina [34].

Conforme apontado por Barata e Kayser [35], as principais correntes na literatura sobre a Indústria 5.0 são orientadas para o futuro e intersectoriais. Enquanto a Indústria 4.0 utiliza tecnologias digitais para resolver problemas específicos de fabricação e melhorar a produtividade, a Indústria 5.0 busca um propósito mais amplo, não apenas com uma visão mais centrada no cliente, mas também com um foco maior no ser humano. Pode-se, portanto, argumentar que a Indústria 5.0 não é guiada pela tecnologia, mas sim pelo valor. A Indústria 5.0 enxerga o ser humano, por um lado, como um consumidor que espera

produtos personalizados em larga escala e, por outro, como um trabalhador qualificado que interage com robôs para viabilizar essa personalização.

Na Indústria 5.0, a ênfase estará na colaboração entre humanos e máquinas, onde as decisões orientadas por dados serão combinadas com a intuição e a criatividade humana para gerar soluções mais inovadoras e personalizadas. Os sistemas de decisão se tornarão mais autônomos e capazes de aprender com os dados em tempo real, adaptando-se rapidamente às mudanças no ambiente de negócios e nas demandas do mercado.

Com o aumento do uso de decisões automatizadas, surgirá a necessidade de garantir que essas decisões sejam tomadas de maneira ética e transparente. A explicabilidade dos algoritmos de decisão será crucial para conquistar a confiança dos *stakeholders*. O futuro dos sistemas de decisão também estará alinhado com práticas de sustentabilidade, onde as decisões não apenas maximizam o lucro, mas também consideram os impactos ambientais e sociais, promovendo uma indústria mais responsável.

## 1.7. Estudo de Caso

A transformação digital na indústria tem impulsionado a adoção de tecnologias avançadas, como a inteligência artificial (IA) e a Internet das Coisas (IoT), no monitoramento e na manutenção de equipamentos industriais. No contexto da Indústria 5.0, que enfatiza a colaboração entre humanos e máquinas inteligentes, a manutenção preditiva emerge como uma prática essencial para maximizar a eficiência operacional e reduzir custos associados a falhas inesperadas. Este estudo de caso teórico foca na implementação de um Sistema de Recomendação para Manutenção Preditiva em uma fábrica moderna, alinhada aos princípios da Indústria 5.0.

A empresa analisada, referida como Indústria XYZ, opera em um setor onde a continuidade dos processos produtivos é importante para a competitividade no mercado. Com o objetivo de minimizar o tempo de inatividade e otimizar a utilização dos recursos, a empresa enfrenta o desafio de integrar um sistema que não apenas preveja falhas iminentes, mas também recomende ações corretivas de forma proativa. Para isso, é necessário desenvolver um sistema inteligente capaz de analisar dados sensoriais em tempo real e fornecer recomendações precisas para manutenção, utilizando técnicas de aprendizado de máquina e análise preditiva [18].

Este estudo de caso explora teoricamente cada etapa do desenvolvimento do sistema, desde a preparação dos dados, passando pelo treinamento dos modelos de aprendizado de máquina, até a implementação e validação em um ambiente de produção real. O objetivo principal é demonstrar como a integração de tecnologias avançadas e o conhecimento especializado dos operadores podem transformar processos industriais, tornando-os mais resilientes, personalizados e eficientes. A capacidade de prever falhas e tomar decisões rápidas, fundamentadas em dados robustos e em tempo real, representa uma vantagem competitiva significativa para empresas que buscam se adaptar às exigências da Indústria 5.0 [19].

### 1.7.1. Fundamentos e Preparação de Dados

A Figura 1.4 ilustra o fluxo completo de preparação de dados, desde a coleta inicial até a divisão final dos dados em conjuntos de treino, validação e teste. Esta imagem proporciona uma visão clara das interconexões entre as diferentes etapas e como elas se complementam para formar um pipeline de dados eficiente e robusto.



Figura 1.4: Fluxo de preparação de dados.

A primeira etapa na construção de um sistema de recomendação para manutenção preditiva é a preparação dos dados. A coleta de dados é importante e deve ser realizada de maneira sistemática e contínua, utilizando sensores instalados nas máquinas e equipamentos ao longo da linha de produção. Esses sensores devem monitorar variáveis críticas, como temperatura, vibração e pressão, que são indicativas do estado de funcionamento das máquinas e da qualidade do produto final [36].

Após a coleta, os dados brutos frequentemente contêm inconsistências, valores ausentes e ruídos que podem comprometer a eficácia do modelo. Por isso, a limpeza dos dados é uma etapa fundamental. Ela envolve a remoção de entradas duplicadas, o tratamento de valores ausentes por meio de imputação e a padronização dos dados. A limpeza dos dados assegura que o conjunto de dados seja robusto e confiável, o que é essencial para o sucesso das etapas subsequentes de modelagem [37].

Em seguida, deve-se realizar a engenharia de *features*. Esta etapa é vital para identificar e selecionar as variáveis que realmente impactam o desempenho do modelo. Em um cenário típico, como o da Indústria XYZ, onde há uma grande quantidade de recursos disponíveis, a seleção de *features* ajuda a reduzir a complexidade do modelo, concentrando-se nas variáveis mais relevantes. A engenharia de *features* é particularmente crítica em sistemas de manutenção preditiva, como demonstrado na indústria automotiva, onde a seleção e transformação adequadas de *features* podem melhorar significativamente a precisão das previsões de falhas e aumentar a longevidade dos equipamentos [38].

Técnicas como a relação sinal-ruído, testes estatísticos e métodos de seleção como *Relief* e *Pearson* são comumente aplicadas para determinar as variáveis que devem ser mantidas no modelo. Esses métodos são utilizados para a seleção de *features* em vários contextos, incluindo a classificação do câncer de próstata, onde essas técnicas ajudam a identificar as variáveis mais significativas para a construção de modelos preditivos precisos [39].

A normalização e padronização dos dados são igualmente importantes para garantir que diferentes tipos de dados possam ser comparados e utilizados de maneira eficaz pelos modelos de aprendizado de máquina. A normalização ajusta os dados para uma escala comum, enquanto a padronização assegura que as variáveis tenham distribuições semelhantes, facilitando o processo de aprendizado dos algoritmos e garantindo que nenhuma variável domine o modelo por estar em uma escala maior [40].

Finalmente, a divisão dos dados em conjuntos de treino, validação e teste é necessária para garantir a eficácia do modelo. A validação cruzada [41] é uma técnica comum utilizada para avaliar o desempenho do modelo, permitindo que ele seja testado em diferentes segmentos do conjunto de dados. Essa abordagem ajuda a evitar o sobreajuste, garantindo que o modelo possa generalizar bem para novos dados, um requisito crucial para a implementação em um ambiente de produção real [42].

### 1.7.2. Desenvolvimento de Modelos de *Machine Learning*

O desenvolvimento de um sistema de recomendação para manutenção preditiva envolve um ciclo iterativo contínuo, conforme ilustrado na Figura 1.5. Este ciclo começa com a seleção dos algoritmos de aprendizado de máquina mais adequados, seguido pelo treinamento dos modelos com os dados disponíveis. Após o treinamento, o modelo passa por ajustes de hiperparâmetros e validação cruzada para otimizar seu desempenho. A etapa final do ciclo envolve a avaliação do modelo. Dependendo dos resultados obtidos, o ciclo pode recomeçar, permitindo ajustes contínuos e refinamentos no modelo, garantindo sua robustez e eficácia em um ambiente de produção. Esse processo iterativo é essencial para o desenvolvimento eficaz de modelos de aprendizado de máquina [43]. Além disso, métricas como F1 Score são cruciais para fornecer uma avaliação equilibrada do desempenho do modelo, especialmente em cenários com desequilíbrio entre as classes, onde é necessário um equilíbrio entre precisão e recall [44].

Esse ciclo iterativo é essencial para assegurar que o modelo final atenda às exigências de precisão e adaptabilidade, características fundamentais na Indústria 5.0. Nos parágrafos a seguir, são detalhadas as principais etapas desse fluxo de desenvolvimento, desde a seleção dos algoritmos até a avaliação do modelo, com ênfase nos métodos e técnicas aplicadas em cada fase.

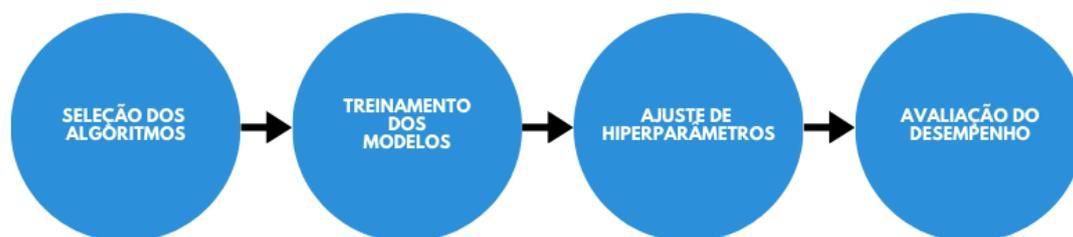


Figura 1.5: Ciclo iterativo no desenvolvimento de um sistema de recomendação para manutenção preditiva, ilustrando as etapas de seleção de algoritmos, treinamento dos modelos, ajuste de hiperparâmetros e avaliação do desempenho.

A primeira etapa no desenvolvimento de um sistema de recomendação para manutenção preditiva é a seleção dos algoritmos mais adequados para o problema em questão. No contexto da Indústria 5.0, onde a precisão e a capacidade de adaptação são essenciais, algoritmos como regressão logística [45], árvores de decisão [46], florestas aleatórias [47] e redes neurais profundas [48] são frequentemente considerados.

Cada um desses algoritmos possui características únicas que os tornam mais ou menos adequados para diferentes tipos de problemas. Por exemplo, redes neurais pro-

fundas são extremamente eficazes em capturar padrões complexos em grandes volumes de dados, mas podem ser mais desafiadoras para treinar e interpretar. Por outro lado, as árvores de decisão são mais simples e interpretáveis, mas podem sofrer de sobreajuste se não forem reguladas adequadamente. Portanto, a escolha do algoritmo deve equilibrar a precisão, interpretabilidade e a capacidade de generalização.

O treinamento dos modelos é a fase em que os algoritmos são ajustados aos dados de treinamento. Durante o treinamento, os algoritmos aprendem a partir dos padrões presentes nos dados, ajustando seus parâmetros para minimizar o erro nas previsões. Técnicas como o ajuste de hiperparâmetros e a validação cruzada são comumente utilizadas nesta fase para otimizar o desempenho do modelo [44]. O objetivo é desenvolver um modelo que não apenas tenha um bom desempenho no conjunto de treinamento, mas que também seja capaz de generalizar para novos dados, garantindo sua eficácia em um ambiente de produção.

A avaliação do desempenho dos modelos é realizada utilizando o conjunto de validação e, posteriormente, o conjunto de teste. Métricas como acurácia, precisão, *recall* e a métrica F1 são empregadas para avaliar a eficácia do modelo. A escolha das métricas depende dos objetivos específicos do sistema de manutenção preditiva. Por exemplo, em um ambiente onde a detecção de falhas é crítica, o *recall* pode ser mais importante que a precisão, pois assegura que a maioria das falhas seja detectada, mesmo que isso resulte em alguns falsos positivos.

### 1.7.3. Implementação e Testes do Sistema de Decisão

Após o desenvolvimento e a avaliação dos modelos de aprendizado de máquina, a próxima etapa é a implementação do sistema de decisão em um ambiente de produção. A Figura 1.6 ilustra as etapas envolvidas nesse processo, desde a integração inicial do modelo até a manutenção contínua após a implementação. Esse fluxo de trabalho cíclico garante que o sistema permaneça eficaz e adaptável às necessidades em constante evolução da Indústria XYZ.



Figura 1.6: Fluxo das etapas de implementação de um sistema de decisão para manutenção preditiva, começando com a integração do modelo ao sistema de monitoramento, seguido pelo desenvolvimento da interface do usuário, testes em ambiente controlado, e finalizando com a manutenção contínua e monitoramento pós-implementação.

Essa fase inicia com a integração do modelo ao sistema de monitoramento existente na Indústria XYZ. Isso inclui a configuração de interfaces para a coleta contínua de

dados sensoriais, o processamento em tempo real e a geração automatizada de recomendações de manutenção.

A interface do usuário desempenha um papel crucial no sistema, pois é por meio dela que os operadores interagem com as recomendações geradas pelo modelo. Uma interface bem projetada deve ser intuitiva, facilitando a compreensão das previsões pelos operadores e permitindo que eles tomem decisões informadas de forma ágil. A visualização clara dos dados e das recomendações é essencial para garantir que os operadores possam interpretar rapidamente as informações e tomar ações corretivas imediatas. A importância de uma interface de usuário eficaz é destacada na literatura como um fator essencial para aumentar a confiança dos operadores nas decisões automatizadas e melhorar a adoção da tecnologia [49].

Antes da implantação completa, o sistema deve ser submetido a testes rigorosos em um ambiente controlado. Esses testes envolvem a simulação de diferentes cenários de falhas e a avaliação da resposta do sistema a essas situações. Esse processo é fundamental para identificar quaisquer ajustes necessários no modelo ou na interface do usuário, garantindo que o sistema funcione conforme o esperado em condições reais de operação.

A manutenção contínua do sistema após a implementação é igualmente essencial. O sistema deve ser monitorado constantemente para garantir sua eficácia a longo prazo. Atualizações regulares nos modelos e ajustes baseados em novos dados são necessários para manter o sistema relevante e eficaz. A capacidade de adaptação do sistema, aliada à sua robustez, permite que a Indústria XYZ opere de forma eficiente e segura, minimizando o tempo de inatividade e os custos associados a falhas inesperadas. A importância dessa abordagem é destacada na literatura, que demonstra como a manutenção contínua e as atualizações são cruciais para reduzir o tempo de inatividade e evitar custos adicionais causados por falhas inesperadas [50].

## **1.8. Conclusões**

A evolução da Indústria 4.0 para a Indústria 5.0 representa uma mudança paradigmática na forma como as empresas abordam a produção e a gestão de processos. Enquanto a Indústria 4.0 se concentrou na automação e na eficiência através da digitalização e da conectividade, a Indústria 5.0 vai além, buscando reintegrar o ser humano no centro dos processos produtivos. Esta nova fase industrial não apenas adota tecnologias avançadas como a inteligência artificial, aprendizado de máquina, e Internet das Coisas (IoT), mas também valoriza a colaboração entre humanos e máquinas, promovendo um ambiente de trabalho mais personalizado, sustentável e ético.

Neste trabalho, exploramos a implementação de sistemas de decisão baseados em dados como uma aplicação prática dos princípios da Indústria 5.0. O estudo de caso da Indústria XYZ, que desenvolveu um sistema de recomendação para manutenção preditiva, exemplifica como a integração de tecnologia avançada com o conhecimento humano pode otimizar processos industriais. Através de uma análise detalhada das etapas de preparação de dados, desenvolvimento de modelos de aprendizado de máquina, e implementação prática do sistema, foi demonstrado que essas tecnologias podem transformar a maneira como as empresas operam, tornando-as mais resilientes, eficientes e adaptáveis às demandas do mercado.

A Indústria 5.0 oferece inúmeras vantagens, incluindo a capacidade de personalizar produtos e serviços de acordo com as necessidades individuais dos clientes, reduzir o impacto ambiental através da economia circular e promover um ambiente de trabalho mais colaborativo. No entanto, também apresenta desafios significativos, como a necessidade de mudanças culturais nas empresas, o aumento da demanda por profissionais qualificados, e a complexidade da integração de sistemas tecnológicos avançados. Este trabalho destaca a importância de abordar esses desafios de forma proativa, garantindo que as empresas possam tirar o máximo proveito das oportunidades oferecidas pela Indústria 5.0.

Trabalhos futuros devem se concentrar em várias áreas para expandir o impacto da Indústria 5.0. Primeiramente, é essencial desenvolver novas metodologias e ferramentas que facilitem a integração harmoniosa entre humanos e máquinas, assegurando que a tecnologia realmente amplifique as capacidades humanas. Além disso, pesquisas adicionais são necessárias para explorar como os sistemas de decisão baseados em dados podem ser aplicados em diferentes setores industriais, ampliando seu alcance e eficácia. Outra área promissora é o desenvolvimento de algoritmos de inteligência artificial que não apenas aprendam e adaptem-se em tempo real, mas também garantam transparência e ética em suas decisões, ganhando a confiança dos usuários. Por fim, estudos devem investigar como as empresas podem superar as barreiras culturais e tecnológicas para adotar plenamente as práticas da Indústria 5.0, assegurando que essa evolução industrial seja inclusiva, sustentável e benéfica para todos os envolvidos.

## Referências

- [1] Edvânia da Glória Silva. *O efeito da indústria 5.0 na produção*. PhD thesis, 2023.
- [2] Henning Kagermann, Johannes Helbig, Ariane Hellinger, and Wolfgang Wahlster. *Recommendations for implementing the strategic initiative INDUSTRIE 4.0: Securing the future of German manufacturing industry; final report of the Industrie 4.0 Working Group*. Forschungsunion, 2013.
- [3] Carolina Narvaez Rojas, Gustavo Adolfo Alomia Peñafiel, Diego Fernando Loaiza Buitrago, and Carlos Andrés Tavera Romero. Society 5.0: A japanese concept for a superintelligent society. *Sustainability*, 13(12):6567, 2021.
- [4] John Andrew van der Poll. Problematizing the adoption of formal methods in the 4ir–5ir transition. *Applied System Innovation*, 5(6):127, 2022.
- [5] Ray Y Zhong, Xun Xu, Eberhard Klotz, and Stephen T Newman. Intelligent manufacturing in the context of industry 4.0: a review. *Engineering*, 3(5):616–630, 2017.
- [6] Jiewu Leng, Weinan Sha, Baicun Wang, Pai Zheng, Cunbo Zhuang, Qiang Liu, Thorsten Wuest, Dimitris Mourtzis, and Lihui Wang. Industry 5.0: Prospect and retrospect. *Journal of Manufacturing Systems*, 65:279–295, 2022.
- [7] James A O'brien and George M Marakas. *Administração de sistemas de informação*. AMGH, 2013.

- [8] Tharcylla Rebecca Negreiros Clemente Pedro Henrique Cavalcanti Lins Andre Gardi Koury Marcelo Hazin Alencar Cristiano Alexandre Virginio Cavalcante. Sistema de apoio a decisão para definição de estratégias de manutenção a partir da abordagem mcc. In *XXXI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO*, Belo Horizonte, Minas Gerais, oct 2011.
- [9] George Anthony Gorry and Michael S Scott Morton. A framework for management information systems. 1971.
- [10] R. Bloemen and J. Maes. A dss for optimizing the aggregate production planning at monsanto antwerp. *European Journal of Operational Research*, 61(1):30–40, 1992. IFORS-SPC Conference on Decision Support Systems.
- [11] M Bruccoleri, G Lo Nigro, S La Noto Diega, P Renna, and G Perrone. A dss for strategic planning. *Design of Advanced Manufacturing Systems: Models for Capacity Planning in Advanced Manufacturing Systems*, pages 37–71, 2005.
- [12] Daniel J Power. *Decision support systems: concepts and resources for managers*, volume 13. Quorum Books Westport, 2002.
- [13] Claus Weihs and Katja Ickstadt. Data science: the impact of statistics. *International Journal of Data Science and Analytics*, 6:189–194, 2018.
- [14] Muhammet Atalay and Enes Çelik. Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları - artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22):155–172, 2017.
- [15] Mayra dos Santos Guidorizzi Ana Paula Bispo dos Santos André Barbosa de Oliveira Fabrizio Leonardi. Simulação como apoio a tomada de decisão para a solução de problemas causados pelos gargalos formados no trânsito. In *XXIX ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO*, Salvador, Bahia, oct 2009.
- [16] George S Fishman. *Discrete-event simulation: modeling, programming, and analysis*, volume 537. Springer, 2001.
- [17] Praveen Kumar Reddy Maddikunta, Quoc-Viet Pham, Prabadevi B, N Deepa, Kapal Dev, Thippa Reddy Gadekallu, Rukhsana Ruby, and Madhusanka Liyanage. Industry 5.0: A survey on enabling technologies and potential applications. *Journal of Industrial Information Integration*, 26:100257, 2022.
- [18] Ashok Vajravelu, Yamunarani Thanikachalam, Mohd Helmy Bin Abd Wahab, Muhammad Mahadi Abdul Jamil, and S. Sivaranjani. Human-machine collaboration and emotional intelligence in industry 5.0. *Advances in computational intelligence and robotics book series*, pages 220–232, 2024.
- [19] Andreas Eschbach. Postagem do conselho: Como o setor 5.0 transformará a manufatura de processos como a conhecemos, 2021. Acessado em: 12 de agosto de 2024.

- [20] Bahar Asgarova, Elvin Jafarov Elvin Jafarov, Nicat Babayev, Allahshukur Ahmadzada, Abdullayev V.H, and Triwiyanto Triwiyanto. Development process of decision support systems using data mining technology. *Indonesian Journal of Electrical Engineering and Computer Science*, 36(1):703–703, 2024.
- [21] Shima Maniyan, Rouzbeh Ghousi, and Abdorrahman Haeri. Data mining-based decision support system for educational decision makers: Extracting rules to enhance academic efficiency. 2024.
- [22] Gerald Van Amburg. Management information system (mis), 2022.
- [23] Arihant Chhajer. Expert systems for emulating the decision making ability of a human expert. *TechnoareteTransactions on Intelligent Data Mining and Knowledge Discovery*, 1(1):15–18, 2022.
- [24] Ewerton Alex Avelar and Ricardo Vinícius Dias Jordão. The role of artificial intelligence in the decision-making process: a study on the financial analysis and movement forecasting of the world's largest stock exchanges. *Management Decision*, 2024.
- [25] Ahmad Talal Ali. Systems and methods for predicting environmental conditions, 2021.
- [26] Mariusz Żytniewski. Autopoietic knowledge management systems. pages 364–379. IGI Global, 2020.
- [27] Dr. Ram Bajaj. (6) "mastering the art of strategic planning: A blueprint for success". *Journal for ReAttach therapy and developmental diversities*, 2023.
- [28] Andriy Zaverbnyj and Vitalii Ilnytskyi. Phases of the life cycle of projects as a key factor in the success of their implementation. *Infrastruktura rinku*, (78), 2023.
- [29] Sri Wulandari and Hapzi Ali. Determination of management decision quality: Integration, effectiveness, development of management information systems. *Dinasti International Journal of Management Science (DIJMS)*, 2023.
- [30] Anaïs Barbier, C. Rousselière, Laurine Robert, E Cousein, and Bertrand Décaudin. Elaboration d'un guide méthodologique sur l'implantation d'un système d'aide à la décision pharmaceutique: retour d'expérience d'un centre hospitalier universitaire français. *Annales pharmaceutiques françaises*, 81(1):163–172, 2022.
- [31] Oleksandr V. Darushyn, Sergiy Bodenчук, and Ivan Buzian. Development and implementation technology of managerial decisions in enterprise management. *Naukovij poglâd: ekonomika ta upravlinnâ*, (2(86)), 2023.
- [32] Rosário Macário, Vasco Reis, and Juan Pablo Antún. Assessment at different stages of implementation. pages 233–243. Elsevier BV, 2023.
- [33] Tim Stobierski. The advantages of data-driven decision-making, 2019. Disponível em: <https://online.hbs.edu/blog/post/data-driven-decision-making>. Acesso em: 25 ago. 2024.

- [34] Ecanorea. Industry 5.0: The new business revolution, 2023. Disponível em: <https://www.plainconcepts.com/industry-50/>. Acesso em: 25 ago. 2024.
- [35] João Barata and Ina Kayser. Industry 5.0 – past, present, and near future. *Procedia Computer Science*, 219:778–788, 2023. CENTERIS – International Conference on ENTERprise Information Systems / ProjMAN – International Conference on Project MANagement / HCist – International Conference on Health and Social Care Information Systems and Technologies 2022.
- [36] Mudita Uppal, Deepali Gupta, Nitin Goyal, Agbotiname Lucky Imoize, Arun Kumar, Stephen Ojo, Subhendu Kumar Pani, Yongsung Kim, and Jaeun Choi. A real-time data monitoring framework for predictive maintenance based on the internet of things. *Complexity*, 2023(1):9991029, 2023.
- [37] Idrus Assagaf, Agus Sukandi, and Abdul Azis Abdillah. Machine failure detection using deep learning. *Recent in Engineering Science and Technology*, 1(03):26–31, Jul. 2023.
- [38] Venkata Sushma Chinta, Sowmya Kethi Reddi, and Nagini Yarramsetty. Optimal feature selection on serial cascaded deep learning for predictive maintenance system in automotive industry with fused optimization algorithm. *Advanced Engineering Informatics*, 57:102105, 2023.
- [39] Sunil Kumar Prabhakar and Seong-Whan Lee. Transformation based tri-level feature selection approach using wavelets and swarm computing for prostate cancer classification. *IEEE Access*, 8:127462–127476, 2020.
- [40] Marcellino Bonamutial and Simeon Yuda Prasetyo. Exploring the impact of feature data normalization and standardization on regression models for smartphone price prediction. In *2023 International Conference on Information Management and Technology (ICIMTech)*, pages 294–298, 2023.
- [41] Payam Refaeilzadeh, Lei Tang, and Huan Liu. *Cross-Validation*, pages 532–538. Springer US, Boston, MA, 2009.
- [42] İbrahim Yazıcı and Emre Gures. A novel approach for machine learning-based load balancing in high-speed train system using nested cross validation. In *2023 10th International Conference on Wireless Networks and Mobile Communications (WINCOM)*, pages 1–6, 2023.
- [43] Ramona Leenings, Nils Ralf Winter, Lucas Plagwitz, Vincent Holstein, Jan Ernsing, Kelvin Sarink, Lukas Fisch, Jakob Steenweg, Leon Kleine-Vennekate, Julian Gebker, Daniel Emden, Dominik Grotegerd, Nils Opel, Benjamin Risse, Xiaoyi Jiang, Udo Dannlowski, and Tim Hahn. Photonai—a python api for rapid machine learning model development. *PLOS ONE*, 16(7):1–19, 07 2021.
- [44] Sina Shafiezadeh, Gian Marco Duma, Giovanni Mento, Alberto Danieli, Lisa Antoniazzi, Fiorella Del Popolo Cristaldi, Paolo Bonanni, and Alberto Testolin. Methodological issues in evaluating machine learning models for eeg seizure prediction:

Good cross-validation accuracy does not guarantee generalization to new patients. *Applied Sciences*, 13(7), 2023.

- [45] Michael P. LaValley. Logistic regression. *Circulation*, 117(18):2395–2399, 2008.
- [46] Barry de Ville. Decision trees. *WIREs Computational Statistics*, 5(6):448–455, 2013.
- [47] Adele Cutler, D. Richard Cutler, and John R. Stevens. *Random Forests*, pages 157–175. Springer New York, New York, NY, 2012.
- [48] Daniel Durstewitz, Georgia Koppe, and Andreas Meyer-Lindenberg. Deep neural networks in psychiatry. *Molecular Psychiatry*, 24(11):1583–1598, Nov 2019.
- [49] Md Abdul Kadir, Abdulrahman Mohamed Selim, Michael Barz, and Daniel Sonntag. A user interface for explaining machine learning model explanations. In *Companion Proceedings of the 28th International Conference on Intelligent User Interfaces*, IUI '23 Companion, page 59–63, New York, NY, USA, 2023. Association for Computing Machinery.
- [50] Mounia Achouch, Mariya Dimitrova, Rizck Dhouib, Hussein Ibrahim, Mehdi Adda, Sasan Sattarpanah Karganroudi, Khaled Ziane, and Ahmad Aminzadeh. Predictive maintenance and fault monitoring enabled by machine learning: Experimental analysis of a ta-48 multistage centrifugal plant compressor. *Applied Sciences*, 13(3), 2023.