



A influência das tecnologias de IA na Gestão de Processos e da Qualidade no setor Industrial

SÉRGIO RICARDO SILVA
(Licenciado em Engenharia Eletrónica e de Telecomunicações)

Dissertação para obtenção do grau de Mestre em Engenharia e Gestão Industrial

Orientador:

Doutor Vítor Manuel Rodrigues Anes

Júri:

Presidente: Doutor João Nuno Pinto Miranda Garcia

Vogais:

Doutora Márcia Lourenço Baptista

Doutor Vítor Manuel Rodrigues Anes

Dezembro, 2025

A influência das tecnologias de IA na Gestão de Processos e da Qualidade no setor Industrial

SÉRGIO RICARDO SILVA
(Licenciado em Engenharia Eletrónica e de Telecomunicações)

Dissertação para obtenção do grau de Mestre em Engenharia e Gestão Industrial

Orientador:

Doutor Vítor Manuel Rodrigues Anes, ISEL/IPL

Júri:

Presidente: Doutor João Nuno Pinto Miranda Garcia, ISEL/IPL

Vogais:

Doutora Márcia Lourenço Baptista, FCUL

Doutor Vítor Manuel Rodrigues Anes, ISEL/IPL

Agradecimentos

A Deus, pela graça, proteção e força que me sustentou ao longo de todo este percurso. Sem a Sua presença, este trabalho não teria sido possível.

À minha família, pelo amor incondicional, pela educação, pelos valores e pela paciência nas horas de maior exigência. Obrigado pelo apoio constante, pelas palavras de encorajamento e por acreditarem em mim mesmo quando o caminho pareceu mais difícil.

Aos amigos que o ISEL me proporcionou, pela camaradagem, pelo apoio, pelas partilhas de conhecimento e pela ajuda mútua nas semanas mais intensas. A vossa amizade transformou o esforço académico numa experiência humana inesquecível.

Um agradecimento especial a Ednilton Silva, Bruno Cadilha e o Prof. Vítor, pelo apoio, pela disponibilidade e pelas contribuições concretas que acrescentaram rigor e qualidade a esta dissertação. A vossa partilha de experiência e sentido crítico foram determinantes para ultrapassar obstáculos e aperfeiçoar este trabalho.

Declaração de integridade

Declaro que esta dissertação é o resultado da minha investigação pessoal e independente. O seu conteúdo é original e todas as fontes listadas nas referências bibliográficas foram consultadas e estão devidamente mencionadas no texto. Mais declaro que todas as referências científicas e técnicas relevantes para o desenvolvimento do trabalho estão devidamente citadas e constam das referências bibliográficas.

O autor

A handwritten signature in black ink, reading "Sérgio R. N. da Silva". The signature is written in a cursive style and is positioned above a horizontal line.

Lisboa, 15 de dezembro de 2025

A influência das tecnologias de IA na Gestão de Processos e da Qualidade no setor Industrial

Resumo

A presente dissertação analisa a influência das tecnologias de Inteligência Artificial (IA) na gestão de processos e da qualidade nas organizações, evidenciando o seu papel estratégico na transformação digital e na criação de vantagens competitivas sustentáveis. Neste enquadramento, a presente dissertação tem como objetivo analisar criticamente o contributo da IA para a gestão de processos e da qualidade em ambientes industriais, identificando impactos, benefícios, riscos e limitações, com base na evidência da literatura científica recente. A metodologia adotada assenta numa revisão sistematizada da literatura e na análise comparativa de estudos de caso reais, selecionados segundo critérios de relevância científica e aplicabilidade industrial. Os casos analisados abrangem diferentes domínios de aplicação da IA, nomeadamente o controlo e previsão da qualidade, a monitorização e otimização de processos através de gémeos digitais e a automatização da inspeção visual, recorrendo a técnicas de *machine learning* e *deep learning*. A análise incide sobre a integração destas soluções nos processos produtivos, os dados utilizados, os métodos de validação e os resultados reportados.

Os resultados mostram o potencial da IA para apoiar a tomada de decisão, reforçar a capacidade de previsão e deteção de desvios de qualidade e reduzir a dependência de inspeções manuais. Contudo, demonstram também que os benefícios obtidos dependem fortemente da qualidade dos dados, da maturidade tecnológica das organizações e da integração efetiva das soluções nos sistemas existentes, sendo ainda identificadas limitações relacionadas com a interpretabilidade, escalabilidade e competências necessárias.

Conclui-se que a IA constitui um instrumento relevante para a gestão de processos e da qualidade na indústria, desde que a sua adoção seja orientada por uma abordagem estruturada e crítica, alinhada com os objetivos organizacionais.

Palavras-chave: Inteligência Artificial; Indústria 4.0; Gestão de Processos; Gestão da Qualidade; *Machine Learning*; *Deep Learning*; Controlo e Previsão da Qualidade; Gémeo Digital; Inspeção Visual Automatizada; Estudos de Caso.

The influence of AI technologies on Process and Quality Management in the industrial sector.

Abstract

This dissertation analyzes the influence of Artificial Intelligence (AI) technologies on process and quality management in organizations, highlighting their strategic role in digital transformation and the creation of sustainable competitive advantages. Within this framework, this dissertation aims to critically analyze the contribution of AI to process and quality management in industrial environments, identifying impacts, benefits, risks, and limitations, based on evidence from recent scientific literature. The methodology adopted is based on a systematic literature review and a comparative analysis of real case studies, selected according to criteria of scientific relevance and industrial applicability. The cases analyzed cover different application domains of AI, namely quality control and prediction, process monitoring and optimization through digital twins, and the automation of visual inspection using machine learning and deep learning techniques. The analysis focuses on the integration of these solutions into production processes, the data used, the validation methods, and the results reported. The results show the potential of AI to support decision-making, strengthen the ability to predict and detect quality deviations, and reduce dependence on manual inspections. However, they also demonstrate that the benefits obtained depend heavily on data quality, the technological maturity of organizations, and the effective integration of solutions into existing systems, while limitations related to interpretability, scalability, and necessary skills are also identified.

It is concluded that AI is a relevant tool for process and quality management in industry, provided that its adoption is guided by a structured and critical approach, aligned with organizational objectives.

Keywords: Artificial Intelligence; Industry 4.0; Process Management; Quality Management; Machine Learning; Deep Learning; Quality Control and Prediction; Digital Twin; Automated Visual Inspection; Case Studies.

Lista de Siglas

5S	<i>Metodologia 5S (Seiri, Seiton, Seiso, Seiketsu, Shitsuke)</i>
AI	<i>Artificial Intelligence</i>
AI	<i>Act Artificial Intelligence Act</i>
AI RMF	<i>Artificial Intelligence Risk Management Framework</i>
ANN	<i>Artificial Neural Networks</i>
BERT	<i>Bidirectional Encoder Representations from Transformers</i>
BPM	<i>Business Process Management</i>
BPMN	<i>Business Process Model and Notation</i>
CNN	<i>Convolutional Neural Network</i>
COM	<i>Communication</i>
CPS	<i>Cyber-Physical Systems</i>
DL	<i>Deep Learning</i>
DMAIC	<i>Define, Measure, Analyze, Improve, Control</i>
DT	<i>Digital Twin</i>
DT-ML	<i>Digital Twin com Machine Learning</i>
ELMo	<i>Embeddings from Language Models</i>
ERP	<i>Enterprise Resource Planning</i>
EU	<i>European Union</i>
EurAI	<i>European Association for Artificial Intelligence</i>
FMEA	<i>Failure Mode and Effects Analysis</i>
FAQ	<i>Frequently Asked Questions</i>
GAN	<i>Generative Adversarial Network</i>
GPT	<i>Generative Pre-trained Transformer</i>
GRU	<i>Gated Recurrent Unit</i>
GPU	<i>Graphics Processing Unit</i>
IA	<i>Inteligência Artificial</i>
IDSS	<i>Intelligent Decision Support Systems</i>
IoT	<i>Internet of Things</i>
ISO	<i>International Organization for Standardization</i>
ISO 9001	<i>Quality Management Systems</i>
LLM	<i>Large Language Model</i>
LIDAR	<i>Light Detection and Ranging</i>
LSTM	<i>Long Short-Term Memory</i>
ML	<i>Machine Learning</i>
NIST	<i>National Institute of Standards and Technology</i>
NLG	<i>Natural Language Generation</i>

<i>NLU</i>	<i>Natural Language Understanding</i>
<i>PDCA</i>	<i>Plan, Do, Check, Act</i>
<i>PLN</i>	<i>Processamento de Linguagem Natural</i>
<i>PT</i>	<i>Português</i>
<i>QA</i>	<i>Question Answering</i>
<i>RNN</i>	<i>Recurrent Neural Network</i>
<i>RPA</i>	<i>Robotic Process Automation</i>
<i>SPC</i>	<i>Statistical Process Control</i>
<i>SVM</i>	<i>Support Vector Machine</i>
<i>T5</i>	<i>Text-to-Text Transfer Transformer</i>
<i>TQM</i>	<i>Total Quality Management</i>
<i>UV</i>	<i>Ultravioleta</i>
<i>XAI</i>	<i>Explainable Artificial Intelligence</i>
<i>XCV</i>	<i>Explainable Computer Vision</i>

Índice

AGRADECIMENTOS	I
DECLARAÇÃO DE INTEGRIDADE	III
RESUMO	V
ABSTRACT	VII
LISTA DE SIGLAS	IX
ÍNDICE DE FIGURAS	XIII
ÍNDICE DE TABELAS	XV
1 INTRODUÇÃO	1
1.1 DEFINIÇÃO DO PROBLEMA E OBJETIVOS	3
1.1.1 <i>Identificação dos problemas</i>	3
1.1.2 <i>Propostas</i>	4
1.1.3 <i>Metodologia</i>	4
1.1.4 <i>Objetivos</i>	4
1.2 ESTRUTURA DA DISSERTAÇÃO	5
2 REVISÃO DA LITERATURA	7
2.1 CONCEITOS FUNDAMENTAIS DE INTELIGÊNCIA ARTIFICIAL	7
2.1.1 <i>Principais Abordagens em IA</i>	9
2.1.2 <i>Impacto Económico e Social</i>	9
2.1.3 <i>Paradigmas da Inteligência Artificial</i>	10
2.2 INTELIGÊNCIA ARTIFICIAL NO SETOR INDUSTRIAL: ESTADO DA ARTE	11
2.2.1 <i>Fundamentos da IA</i>	11
2.2.2 <i>Desenvolvimento e Evolução da IA</i>	12
2.2.3 <i>Aplicações da IA</i>	13
2.3 GESTÃO DE PROCESSOS E DA QUALIDADE	14
2.3.1 <i>Evolução Histórica e Conceitual da gestão da qualidade</i>	15
2.3.2 <i>Princípios da Gestão da Qualidade</i>	15
2.3.3 <i>Desenvolvimento da Qualidade em termos de Gestão de Processos</i>	17
2.3.4 <i>Abordagens e metodologia da Gestão da Qualidade</i>	19
2.3.5 <i>Integração entre Gestão de Processos e da Qualidade</i>	20
2.3.6 <i>Desafios na Implementação</i>	21
2.4 MODELOS E TECNOLOGIAS DE IA APLICADAS NA INDÚSTRIA	21
2.4.1 <i>Machine Learning</i>	21
2.4.2 <i>Deep Learning (DL)</i>	24
2.4.3 <i>Processamento de Linguagem Natural (PLN)</i>	26

2.4.4	<i>Visão Computacional</i>	29
2.4.5	<i>Sistemas Especialistas e Robótica Inteligente</i>	32
2.4.6	<i>Chatbots e Assistentes Virtuais</i>	34
2.4.7	<i>Desafios, Barreiras e Riscos da Adoção da IA</i>	35
3	ESTUDO DE CASO	39
3.1	ENQUADRAMENTO E DESCRIÇÃO DO CONTEXTO	39
3.2	APRESENTAÇÃO DOS ESTUDOS DE CASO	40
3.3	METODOLOGIA DE ANÁLISE	42
3.4	ANÁLISE E IDENTIFICAÇÃO DE PROBLEMAS E PADRÕES.....	43
3.4.1	<i>Análise e identificação de problemas por estudo de caso</i>	43
3.4.2	<i>Padrões transversais identificados</i>	45
3.5	PRINCIPAIS CONSTRANGIMENTOS DA APLICAÇÃO DA IA	46
4	PROPOSTAS DE APLICAÇÃO DA IA	49
4.1	FERRAMENTAS E MODELOS PARA OTIMIZAÇÃO DE PROCESSOS.....	49
4.2	SISTEMAS DE CONTROLO DE QUALIDADE AUTOMATIZADO	50
4.3	MANUTENÇÃO PREDITIVA E GESTÃO DE ATIVOS	51
4.4	ESTRATÉGIAS, FORMAÇÃO E MUDANÇA CULTURAL	51
5	ANÁLISE E DISCUSSÃO DO ESTUDO	53
5.1	AVALIAÇÃO DOS RESULTADOS	53
5.2	ANÁLISE E INTERPRETAÇÃO	54
5.3	CONTRIBUIÇÕES, RISCOS E LIMITAÇÕES NA IMPLEMENTAÇÃO	57
6	CONCLUSÕES	59
6.1	PRINCIPAIS CONCLUSÕES.....	59
6.2	LIMITAÇÕES DO ESTUDO	60
6.3	PERSPETIVAS DE INVESTIGAÇÃO FUTURA	60
	REFERÊNCIAS BIBLIOGRÁFICAS	63

Índice de figuras

FIGURA 2.1 - ESTRUTURA BÁSICA DE CONVERGÊNCIA DA REVISÃO DA LITERATURA.	7
FIGURA 2.2 - ETAPAS DE UM MODELO ML.	23
FIGURA 2.3 - PROCESSO DE TREINO DE UM ALGORITMO DE DEEP LEARNING.	25
FIGURA 2.4 - ESTRUTURA GENÉRICA DE UM SISTEMA DE VISÃO COMPUTACIONAL.	30

Índice de Tabelas

TABELA 2.1 - COMPARAÇÃO DE ALGORITMOS ML	24
TABELA 2.2 - PRINCIPAIS ARQUITETURAS DE REDES NEURONAIS PROFUNDAS E RESPECTIVAS APLICAÇÕES.....	26
TABELA 2.3 - PRINCIPAIS MODELOS E ARQUITETURAS DE PLN.....	28
TABELA 2.4 - PRINCIPAIS TÉCNICAS E APLICAÇÕES DE VISÃO COMPUTACIONAL	31
TABELA 2.5 - TIPOS DE CHATBOTS E ASSISTENTES VIRTUAIS NAS ORGANIZAÇÕES.	35
TABELA 3.1 - ANÁLISE E IDENTIFICAÇÃO DE PROBLEMAS POR ESTUDO DE CASO	44
TABELA 3.2 - PADRÕES TRANSVERSAIS IDENTIFICADOS NA APLICAÇÃO DA IA	46
TABELA 5.1 - TABELA COMPARATIVA DO ESTUDO DE CASO	56

1 Introdução

A evolução tecnológica tem vindo a assumir um papel determinante na transformação do setor industrial e nas organizações, contribuindo para melhorias consistentes ao nível da eficiência, da produtividade e da competitividade. Este processo ocorre num contexto caracterizado pela crescente complexidade dos mercados, pela intensificação da concorrência e pela exigência de uma melhoria contínua dos processos organizacionais. A digitalização dos sistemas produtivos, aliada ao aumento da capacidade computacional e à disponibilidade de grandes volumes de dados, tem criado condições propícias à adoção de abordagens analíticas mais avançadas no apoio à gestão das operações e da qualidade (Davenport & Harris, 2017; Brynjolfsson & McAfee, 2017).

A Inteligência Artificial (IA) afirma-se como uma das tecnologias mais relevantes no processo de transformação digital da indústria. De forma geral, a IA pode ser entendida como o conjunto de métodos e técnicas que permitem aos sistemas computacionais desempenhar tarefas que, tradicionalmente, exigiriam capacidades associadas à inteligência humana, como a aprendizagem a partir de dados, o reconhecimento de padrões e o apoio à tomada de decisão em ambientes complexos e dinâmicos (Russell & Norvig, 2022). No contexto industrial, estas capacidades têm vindo a ser progressivamente exploradas com o objetivo de automatizar processos, otimizar operações e apoiar a melhoria sistemática da qualidade.

A aplicação da IA na indústria assenta, em grande medida, no recurso a técnicas de Machine Learning (ML) e Deep Learning (DL). O ML permite que os sistemas identifiquem relações e regularidades a partir de dados históricos, sem necessidade de programação explícita, enquanto o DL, através de arquiteturas baseadas em redes neuronais profundas, tem demonstrado particular eficácia na resolução de problemas de elevada complexidade, como o processamento de imagens, de sinais e de grandes volumes de dados não estruturados (Jordan & Mitchell, 2015; LeCun, Bengio & Hinton, 2015; Alpaydin, 2021).

A integração destas técnicas em sistemas industriais tem vindo a alterar de forma significativa os mecanismos de monitorização e controlo das operações. Em particular, a combinação de DL com sistemas de visão computacional tem permitido avanços relevantes em aplicações de inspeção visual e controlo da qualidade, tradicionalmente dependentes de inspeção manual e, por isso, fortemente condicionadas pela variabilidade humana. A literatura de referência na área do processamento de imagem e da visão computacional descreve de que forma estas abordagens possibilitam a extração automática de características relevantes e a deteção de padrões ou anomalias em contextos industriais complexos (Gonzalez & Woods, 2018; Szeliski, 2022).

De forma complementar, as técnicas de ML têm sido amplamente discutidas como suporte a estratégias de manutenção preditiva. Através da análise de dados provenientes de sensores e sistemas de monitorização, estas abordagens permitem identificar comportamentos anómalos e antecipar potenciais falhas de equipamentos. Representam, assim, uma evolução face às estratégias de manutenção reativa ou preventiva, ao possibilitarem decisões fundamentadas no estado real dos ativos e no seu comportamento ao longo do tempo (Mitchell, 1997; Alpaydin, 2021).

Apesar do potencial reconhecido da IA na gestão de processos e da qualidade, a sua adoção em contexto industrial continua a enfrentar desafios significativos. A literatura identifica dificuldades associadas à complexidade da implementação, à integração com sistemas legados, à necessidade de competências técnicas especializadas e aos investimentos requeridos para o desenvolvimento e manutenção de soluções baseadas em IA (Davenport & Ronanki, 2018). Acrescem ainda preocupações relacionadas com a confiabilidade, a transparência e a possível interpretação dos modelos, aspetos particularmente críticos em ambientes industriais, onde as decisões podem ter impactos relevantes ao nível da segurança, da qualidade e do desempenho operacional (Arrieta et al., 2020).

É neste contexto que a presente dissertação se propõe analisar os impactos atuais e potenciais da IA na gestão de processos e da qualidade no setor industrial. Para esse efeito, recorre-se a uma revisão da literatura e à análise de múltiplos estudos de caso, com o objetivo de identificar as principais aplicações da IA, os benefícios associados e as barreiras à sua adoção. Com base nesta análise, pretende-se ainda propor uma estrutura orientadora que contribua para uma implementação mais eficaz da IA em contexto industrial, promovendo a melhoria contínua dos processos produtivos e o reforço da competitividade das organizações.

1.1 Definição do Problema e Objetivos

A crescente digitalização da indústria tem impulsionado a adoção de tecnologias emergentes, sendo a IA uma das mais promissoras nesse contexto. Seu papel na automação e otimização dos processos produtivos é amplamente reconhecido, contribuindo para ganhos de eficiência, redução de custos e melhoria do controle de qualidade. No entanto, apesar do potencial significativo da IA, sua implementação ainda enfrenta desafios consideráveis. Muitas indústrias continuam a operar com abordagens tradicionais, limitando os benefícios que poderiam ser alcançados por meio da inovação tecnológica.

O problema central desta investigação reside na falta de conhecimento e diretrizes claras para a implementação eficaz da IA nos processos na estrutura. Embora existam diversas soluções tecnológicas disponíveis, as empresas frequentemente enfrentam dificuldades na adoção dessas ferramentas, seja devido à complexidade dos processos, à falta de infraestrutura adequada ou à resistência organizacional à mudança. Diante disso, o desafio consiste em compreender como a IA pode ser aplicada para otimizar a gestão de processos e qualidade, avaliar os seus impactos e identificar as principais barreiras que dificultam sua adoção.

1.1.1 Identificação dos problemas

A dificuldade na implementação da IA na indústria pode ser atribuída a uma série de fatores técnicos, operacionais e organizacionais, entre os quais se destacam:

- Lacunas no enquadramento metodológico, refletidas na ausência de orientações claras e sistemáticas que possam dar suporte a integração prática de soluções de IA nos processos industriais;
- Elevada complexidade dos processos industriais, caracterizados por interdependências, variabilidade e sistemas legados, o que dificulta a incorporação direta de soluções automatizadas e exige adaptações significativas aos fluxos de trabalho existentes;
- Dependência da intervenção humana no controle de qualidade, associada a variabilidade, fadiga e erro, comprometendo a consistência da detecção de defeitos e a eficiência dos processos produtivos;
- Predominância de estratégias de manutenção reativa ou preventiva, resultando em custos operacionais elevados, paragens não planeadas e utilização ineficiente dos recursos;
- Barreiras tecnológicas e organizacionais, incluindo limitações ao nível da infraestrutura digital, resistência à mudança por parte das equipas e necessidade de qualificação dos profissionais para operar e interpretar sistemas baseados em IA.

1.1.2 Propostas

Diante desses desafios, a presente investigação propõe a adoção de ferramentas e modelos de IA para melhorar a gestão de processos e qualidade na indústria. As principais abordagens analisadas incluem:

- Otimização de Processos, utilizando técnicas como *Machine Learning* e outros modelos para prever padrões e aumentar a eficiência operacional;
- Controlo de Qualidade Automatizado, por meio de sistemas de visão computacional e redes neurais capazes de identificar defeitos e garantir padrões de qualidade consistentes;
- Manutenção Preditiva, baseada na análise de dados históricos e em tempo real para antecipar falhas e reduzir custos operacionais.

1.1.3 Metodologia

A presente dissertação se dedica a uma metodologia de investigação baseada numa revisão sistematizada da literatura científica, com o objetivo de analisar a influência das tecnologias de Inteligência Artificial na gestão de processos e da qualidade no setor industrial. A metodologia desenvolve-se nas seguintes fases:

1. Identificação e seleção da literatura científica, abrangendo artigos científicos, estudos de caso documentados e relatórios técnicos relevantes, selecionados com base em critérios de relevância temática e atualidade;
2. Análise e enquadramento conceptual, permitindo caracterizar as principais tecnologias de Inteligência Artificial e os seus domínios de aplicação no contexto industrial, nomeadamente na gestão de processos e no controlo da qualidade;
3. Análise qualitativa de estudos de caso reportados na literatura, com enfoque nas abordagens adotadas, nos dados utilizados, nos objetivos operacionais e nos resultados alcançados;
4. Resumo comparativo e discussão crítica, visando identificar benefícios, limitações, desafios e fatores críticos associados à integração da Inteligência Artificial no setor industrial.

1.1.4 Objetivos

O principal objetivo deste estudo é avaliar os impactos atuais e potenciais da IA na gestão de processos e qualidade no setor industrial. De forma mais específica, pretende-se:

- Analisar a influência dos modelos e tecnologias de IA na redução de custos e no aumento da eficiência operacional;

- Avaliar o contributo da IA para o controlo de qualidade, minimizando falhas e desperdícios;
- Identificar as principais barreiras técnicas e organizacionais para a adoção da IA;
- Apresentar uma estrutura que permita superar as limitações e promover a melhoria contínua nos processos e qualidade.

Ao explorar estas questões, esta investigação pretende contribuir para um melhor entendimento das aplicações da IA na indústria e fornecer recomendações práticas para empresas que procuram modernizar seus processos produtivos e melhorar a competitividade no mercado.

1.2 Estrutura da Dissertação

Esta dissertação está organizada em seis capítulos, estruturados de forma a proporcionar uma compreensão clara e progressiva do tema abordado.

- **Capítulo 1 – Introdução** enquadra o tema da investigação, evidenciando a relevância da Inteligência Artificial no contexto industrial. São apresentados o problema de investigação, os objetivos gerais e específicos do estudo, a metodologia adotada e a estrutura global da dissertação.
- **Capítulo 2 – Revisão da Literatura** desenvolve o enquadramento teórico e conceptual da investigação. Neste capítulo são analisados os principais conceitos e paradigmas da Inteligência Artificial, bem como as suas aplicações no domínio da gestão de processos e da qualidade industrial. São igualmente discutidas as principais tecnologias e abordagens utilizadas, bem como os desafios, barreiras e riscos associados à implementação da IA, permitindo a análise crítica do estado da arte.
- **Capítulo 3 – Estudos de Caso** apresenta a análise de diversos estudos de caso reportados na literatura científica, relativos à aplicação de tecnologias de Inteligência Artificial em contextos industriais reais. São descritos os contextos organizacionais, os objetivos das aplicações, as metodologias adotadas e os principais resultados obtidos, bem como as limitações e desafios identificados nos diferentes casos analisados.
- **Capítulo 4 – Propostas de Aplicação da IA** discute e sistematiza propostas de aplicação da IA na gestão de processos e da qualidade, fundamentadas na revisão da literatura e nos estudos de caso analisados. São abordadas soluções orientadas para a otimização de processos, o controlo de qualidade automatizado e a manutenção preditiva, bem como aspetos críticos relacionados com a integração organizacional e a capacitação das equipas.

- **Capítulo 5 – Análise e Discussão de Resultados** procede à análise comparativa dos múltiplos estudos de caso e das propostas apresentadas, relacionando os resultados reportados na literatura com os objetivos da dissertação. Neste capítulo serão discutidos os impactos, benefícios e limitações da aplicação da Inteligência Artificial no contexto industrial, bem como as implicações para a gestão de processos e da qualidade.
- **Capítulo 6 – Conclusões** resume as principais conclusões da investigação, destacando os contributos do estudo para o conhecimento científico e para a prática industrial. São igualmente identificadas as limitações da dissertação e apresentadas sugestões para futuras linhas de investigação e para o aprofundamento da aplicação da Inteligência Artificial na gestão de processos e da qualidade.

2 Revisão da Literatura

Este capítulo apresenta o enquadramento teórico da dissertação, analisando a aplicação das tecnologias de Inteligência Artificial na gestão de processos e da qualidade no setor industrial. A revisão da literatura adota uma abordagem integrada, articulando os principais modelos e tecnologias de IA com os domínios operacionais e organizacionais da indústria como pode ser visto de uma forma mais estrutural na **Figura 2.1**.



Figura 2.1 - Estrutura básica de Convergência da Revisão da Literatura. Fonte: Elaboração própria

Ao longo do capítulo são discutidos os paradigmas fundamentais da Inteligência Artificial, as suas aplicações na otimização de processos e no controlo da qualidade, bem como os principais desafios e limitações associados à sua adoção.

2.1 Conceitos Fundamentais de Inteligência Artificial

Ao longo da evolução da IA, os investigadores têm adotado diferentes perspetivas conceptuais quanto à definição e ao objeto de estudo da inteligência. Uma parte da literatura define a inteligência com base na semelhança com o desempenho humano,

enquanto outras abordagens privilegiam uma definição mais formal e abstrata, assente no princípio da racionalidade, entendida como a capacidade de agir de forma adequada para atingir determinados objetivos. Em paralelo, existem distinções quanto ao foco da análise, havendo autores que se concentram nos processos internos de pensamento e raciocínio e outros que privilegiam a observação do comportamento inteligente, numa perspetiva externa.

Esta combinação de duas dimensões — *humano versus racional* e *pensamento versus comportamento* — origina diferentes abordagens à IA, cada uma com metodologias e linhas de investigação próprias. As abordagens orientadas para a reprodução da inteligência humana recorrem frequentemente a métodos empíricos inspirados na psicologia e nas ciências cognitivas, baseados na observação do comportamento humano e na formulação de hipóteses sobre os seus processos mentais. Por outro lado, as abordagens racionalistas assentam sobretudo em fundamentos matemáticos e de engenharia, estabelecendo ligações com áreas como a estatística, a teoria da decisão, a teoria do controlo e a economia. Apesar das divergências conceptuais, a interação entre estas correntes tem contribuído de forma decisiva para o progresso do campo (Russell & Norvig, 2022).

De forma geral, a Inteligência Artificial pode ser definida como a área da ciência da computação dedicada ao desenvolvimento de sistemas capazes de executar tarefas que, tradicionalmente, exigiriam capacidades associadas à inteligência humana, como a aprendizagem a partir de dados, o reconhecimento de padrões, o raciocínio e o apoio à tomada de decisão. Esta definição é consistente com a literatura de referência, que enquadra a IA como um domínio interdisciplinar, integrando contributos da informática, matemática, estatística e ciências cognitivas (Russell & Norvig, 2022; Mitchell, 1997).

Os fundamentos da IA remontam a meados do século XX, com contributos pioneiros como o trabalho de Alan Turing, que em 1950 propôs um critério operacional para avaliar a inteligência das máquinas, conhecido como Teste de Turing. Poucos anos depois, John McCarthy introduziu formalmente o termo “Inteligência Artificial” na Conferência de Dartmouth, em 1956, estabelecendo a IA como um campo autónomo de investigação científica. Estes desenvolvimentos iniciais assentaram fortemente em abordagens simbólicas e sistemas baseados em regras, suportados por lógica formal e representações explícitas do conhecimento (Turing, 1950; McCarthy et al., 1956; Russell & Norvig, 2022).

Com o avanço da capacidade computacional e a crescente disponibilidade de dados, a IA evoluiu progressivamente de abordagens simbólicas para modelos orientados por dados, em particular técnicas de *machine Learning* e redes neuronais artificiais. Esta mudança de paradigma permitiu ultrapassar limitações associadas à codificação manual do conhecimento, possibilitando que os sistemas aprendessem diretamente a

partir da experiência. O desenvolvimento de arquiteturas de *deep learning* marcou um ponto de viragem, ao demonstrar desempenho superior em tarefas complexas como visão computacional, processamento de linguagem natural e reconhecimento de padrões em grande escala (Mitchell, 1997; LeCun, Bengio & Hinton, 2015; Goodfellow, Bengio & Courville, 2016).

Este progresso foi impulsionado por três fatores fundamentais: o aumento exponencial da capacidade de processamento, a disponibilidade de grandes volumes de dados e o desenvolvimento de algoritmos de aprendizagem mais eficientes. A convergência destes elementos permitiu a aplicação prática de técnicas anteriormente limitadas a contextos experimentais, acelerando a adoção da IA em ambientes reais (Jordan & Mitchell, 2015; Alpaydin, 2021). Como resultado, a IA passou a desempenhar um papel central em múltiplos setores, incluindo a saúde, as comunicações, as finanças, os transportes e o setor industrial, evidenciando o seu carácter transversal e o seu impacto estruturante na economia e na sociedade (Russell & Norvig, 2022; Brynjolfsson & McAfee, 2017).

2.1.1 Principais Abordagens em IA

Entre as principais abordagens da IA, destacam-se:

- Redes neurais artificiais: Inspiradas no funcionamento do cérebro humano, estas redes permitem o reconhecimento de padrões e a aprendizagem baseada em dados.
- Algoritmos de aprendizagem de máquina (*machine learning*): Técnicas que possibilitam a melhoria do desempenho dos sistemas à medida que estes analisam mais dados.
- Sistemas especialistas: Baseiam-se em regras predefinidas para tomar decisões dentro de domínios específicos.

Com o avanço da investigação, novas áreas como a IA explicável (XAI) e a ética na IA têm ganhado relevância, promovendo maior transparência e equidade nos sistemas inteligentes.

2.1.2 Impacto Económico e Social

O seu crescente uso tem suscitado um debate relevante sobre os seus impactos económicos e sociais, particularmente no contexto da transformação organizacional e dos sistemas produtivos. A literatura reconhece que a IA pode contribuir para ganhos significativos de eficiência e produtividade, sobretudo através da automatização de tarefas, do apoio à tomada de decisão e da otimização de processos, possibilitados

pela capacidade de os sistemas aprenderem a partir de dados e identificarem padrões em contextos complexos (Brynjolfsson & McAfee, 2017; Russell & Norvig, 2022).

No entanto, a criação de valor associada à IA não depende exclusivamente da maturidade tecnológica das soluções adotadas. O sucesso da sua implementação está fortemente condicionado pela capacidade das organizações integrarem estas tecnologias nos seus processos e estruturas existentes, bem como pela disponibilidade de competências especializadas e pelo alinhamento das iniciativas de IA com os objetivos estratégicos (Alpaydin, 2021).

Do ponto de vista tecnológico, a IA tem evoluído segundo diferentes paradigmas, destacando-se os sistemas simbólicos baseados em regras e as abordagens conexionistas assentes em redes neuronais artificiais. O desenvolvimento do deep learning permitiu avanços significativos em áreas como a visão computacional e o processamento de linguagem natural, alcançando elevados níveis de desempenho em tarefas específicas (LeCun et al., 2015; Goodfellow et al., 2016).

2.1.3 Paradigmas da Inteligência Artificial

A IA tem evoluído segundo diferentes paradigmas conceptuais, refletindo distintas formas de representar o conhecimento e de resolver problemas. De forma geral, a literatura identifica dois grandes paradigmas: os sistemas simbólicos baseados em regras e as abordagens conexionistas.

Os sistemas simbólicos, predominantes nas fases iniciais da IA, baseiam-se em lógica formal e regras explícitas para modelar o raciocínio, sendo adequados a domínios bem estruturados. No entanto, a sua aplicação revelou limitações em contextos caracterizados por elevada complexidade, incerteza e grandes volumes de dados (Russell & Norvig, 2022).

As abordagens conexionistas, por sua vez, recorrem a redes neuronais artificiais capazes de aprender diretamente a partir dos dados. Este paradigma ganhou particular relevância com o aumento da capacidade computacional e da disponibilidade de dados, permitindo o desenvolvimento de modelos mais flexíveis e adaptativos (Mitchell, 1997; Alpaydin, 2021).

O avanço do deep learning constituiu um marco significativo neste contexto, possibilitando progressos relevantes em áreas como a visão computacional e o processamento de linguagem natural. Arquiteturas como as redes neuronais convolucionais (CNNs) e as redes neuronais recorrentes (RNNs) demonstraram elevados níveis de desempenho em tarefas específicas e bem delimitadas, como o reconhecimento de imagens e a análise de sequências temporais (LeCun et al., 2015; Goodfellow et al., 2016).

Paralelamente aos avanços tecnológicos, a crescente utilização da IA tem levantado questões éticas e sociais, relacionadas com a transparência, a responsabilidade e a confiança nos sistemas automatizados. A dificuldade de interpretação de modelos complexos motivou o desenvolvimento da Inteligência Artificial Explicável (XAI), bem como a adoção de práticas de governança de dados orientadas para a mitigação de viesamentos e para o cumprimento das regulamentações em vigor, nomeadamente o Regulamento Geral sobre a Proteção de Dados (Gunning & Aha, 2019; Arrieta et al., 2020; European Commission, 2021).

2.2 Inteligência Artificial no setor industrial: Estado da Arte

O estado da arte tem em vista as principais técnicas utilizadas, aplicações e desafios que ainda persistem. Para isso, serão abordadas as bases teóricas da IA, as suas aplicações em diferentes setores industriais e as perspetivas futuras desta tecnologia.

A Inteligência Artificial (IA) tem vindo a transformar a indústria de forma significativa, introduzindo novos paradigmas para a automação, eficiência operacional e tomada de decisões baseada em dados. A evolução das técnicas de IA, incluindo Aprendizagem Automática (Machine Learning - ML) e Redes Neurais Artificiais (Artificial Neural Networks - ANN), tem permitido o desenvolvimento de sistemas capazes de otimizar processos industriais, prever falhas e reduzir custos operacionais.

O conceito de Indústria 4.0 reforça a interligação entre máquinas e processos através da digitalização e estudo inteligente de dados. Com a proliferação da Internet das Coisas (IoT), Big Data e computação em nuvem, as organizações industriais têm cada vez mais apostado na IA para maximizar a sua competitividade.

2.2.1 Fundamentos da IA

A Inteligência Artificial (IA) abrange um vasto conjunto de técnicas destinadas a permitir que as máquinas reproduzam, de forma parcial, capacidades associadas ao raciocínio humano, à aprendizagem e à tomada de decisão. Em contexto organizacional, as abordagens mais discutidas na literatura incluem diferentes paradigmas de aprendizagem e de processamento de informação. A aprendizagem supervisionada consiste na utilização de dados previamente rotulados para treinar modelos capazes de classificar informação e realizar previsões com base em exemplos conhecidos, sendo frequentemente referida na literatura como adequada a tarefas de classificação e previsão em diversos domínios (Alpaydin, 2016; Bishop, 2006). Por sua vez, a aprendizagem não supervisionada tem como objetivo identificar padrões, correlações e estruturas latentes em conjuntos de dados sem rótulos definidos, assumindo particular relevância em análises exploratórias, segmentação e

descoberta de conhecimento em contextos complexos (Han et al., 2011). Outra vertente fundamental é a aprendizagem por reforço, na qual um agente interage com o ambiente e aprende através de um mecanismo de recompensas e penalizações, ajustando progressivamente o seu comportamento com vista à otimização de resultados, sendo amplamente estudada em problemas de controlo, planeamento e sistemas autónomos (Sutton & Barto, 2018).

As redes neuronais artificiais, inspiradas na estrutura e no funcionamento do cérebro humano, destacam-se pela sua capacidade de modelar relações não lineares e reconhecer padrões complexos em dados de elevada dimensão. Estas redes constituem o núcleo das abordagens de deep learning, que têm demonstrado elevado desempenho em diversas tarefas de aprendizagem automática (Goodfellow et al., 2016). Temos também o Processamento de Linguagem Natural (PLN) que representa uma área central da IA, dedicada ao desenvolvimento de métodos que permitem aos sistemas computacionais analisar, interpretar e gerar linguagem humana. As suas aplicações são amplamente discutidas na literatura, abrangendo desde a análise automática de texto até à interação homem-máquina, assumindo um papel crescente no apoio à gestão e ao tratamento da informação em diferentes contextos organizacionais (Jordan & Mitchell, 2015; Russell & Norvig, 2022).

2.2.2 Desenvolvimento e Evolução da IA

A IA não constitui um conceito recente; contudo, o seu impacto na indústria tem-se intensificado de forma significativa nas últimas décadas, em grande medida devido ao aumento do poder computacional disponível e aos avanços registados ao nível dos algoritmos de aprendizagem automática (Jordan & Mitchell, 2015; Russell & Norvig, 2022). A literatura evidencia que a evolução, desde os primeiros sistemas especialistas baseados em regras até aos modelos contemporâneos de deep learning, tem permitido melhorias relevantes em diversos contextos industriais, sobretudo pela capacidade de analisar dados complexos e suportar a automatização de tarefas (Russell & Norvig, 2022; Goodfellow et al., 2016).

O desenvolvimento das redes neuronais artificiais, em particular das arquiteturas profundas, aliado à exploração do processamento paralelo em unidades de processamento gráfico (GPUs), constituiu um fator determinante para estes avanços, ao viabilizar o treino e a execução de modelos em grandes volumes de dados e em tarefas computacionalmente exigentes (LeCun et al., 2015; Owens et al., 2008; Goodfellow et al., 2016).

Adicionalmente, a introdução do conceito de edge computing tem contribuído para reduzir a latência no processamento de informação, ao permitir que parte do tratamento de dados ocorra próximo da sua fonte de geração. Esta abordagem é

particularmente relevante em contextos industriais que exigem resposta em tempo real e elevada fiabilidade, reforçando a eficiência e robustez das soluções baseadas em aprendizagem automática (Shi et al., 2016).

2.2.3 Aplicações da IA

Indústria 4.0 e a Automatização Inteligente

A Indústria 4.0 caracteriza-se pela digitalização da produção e pela interconectividade entre dispositivos e sistemas, integrando tecnologias como sistemas ciber-físicos, Internet das Coisas (IoT) e análise avançada de dados. Neste contexto, a IA desempenha um papel essencial ao permitir a automação inteligente dos processos industriais (Kagermann et al., 2013). Em particular, destacam-se as seguintes aplicações:

- **Robótica Avançada:** Robôs industriais equipados com capacidades de IA são utilizados para realizar tarefas complexas e repetitivas, permitindo maior flexibilidade, precisão e adaptação a ambientes produtivos dinâmicos (Russell & Norvig, 2022);
- **Manutenção Preditiva:** Sensores IoT combinados com algoritmos de aprendizagem automática permitem monitorizar o estado dos equipamentos e prever falhas antes que ocorram, reduzindo paragens não planeadas e custos de manutenção (Sutton & Barto, 2018; Jordan & Mitchell, 2015);
- **Gémeos Digitais (Digital Twins):** Representações virtuais de sistemas e processos físicos possibilitam a simulação, monitorização e optimização das operações industriais ao longo do seu ciclo de vida (Grieves & Vickers, 2017);
- **Otimização de Processos Industriais:** Algoritmos de IA são utilizados para analisar dados de produção em tempo real e ajustar automaticamente parâmetros operacionais, com o objetivo de maximizar a eficiência e a qualidade dos processos produtivos (Alpaydin, 2021).

IA na Produção e Controlo de Qualidade

A IA permite a análise automática de imagens e sinais para a deteção de defeitos em tempo real ao longo do processo produtivo. Em particular, redes neuronais convolucionais (CNNs) têm sido amplamente utilizadas para identificar irregularidades em produtos manufacturados, apresentando elevado desempenho em tarefas de visão computacional (LeCun et al., 2015; Goodfellow et al., 2016). Estas técnicas são especialmente relevantes em setores como a indústria automóvel, aeroespacial e de semicondutores, onde os requisitos de precisão e qualidade são particularmente exigentes (Gonzalez & Woods, 2018). Também salientar técnicas de deteção de

anomalias (anomaly detection) são aplicadas para identificar desvios no comportamento normal dos processos e prever falhas em lotes de produção, permitindo a correção atempada de problemas antes que estes afetem a cadeia produtiva (Chandola et al., 2009; Bishop, 2006).

IA na Cadeia de Suprimentos e Logística

A aplicação de IA na gestão da cadeia de suprimentos permite melhorar a previsão da procura, otimizar rotas de transporte e reduzir desperdícios ao longo da cadeia logística. Algoritmos de aprendizagem automática são utilizados na gestão automatizada de armazéns e inventários, recorrendo a dados históricos e modelos preditivos para ajustar os níveis de stock e evitar situações de escassez ou excesso de produtos (Russell & Norvig, 2022; Alpaydin, 2021).

No domínio da logística, sistemas baseados em IA são utilizados para o planeamento de rotas mais eficientes, contribuindo para a redução dos custos operacionais, do consumo de combustível e do impacto ambiental das operações (Jordan & Mitchell, 2015).

IA na Energia e Sustentabilidade

A utilização da IA na gestão energética permite otimizar o consumo de energia e reduzir a pegada ambiental dos sistemas industriais. Modelos de aprendizagem profunda são aplicados na previsão do consumo energético, no balanceamento da carga e na melhoria da eficiência da distribuição de energia, apoiando estratégias de sustentabilidade e eficiência operacional (LeCun et al., 2015; Goodfellow et al., 2016).

IA em Segurança

A IA é igualmente utilizada para reforçar a segurança em ambientes industriais, através da análise de dados provenientes de sensores e sistemas de vídeo. Estas soluções permitem identificar comportamentos de risco, detetar situações potencialmente perigosas e emitir alertas em tempo útil, contribuindo para a prevenção de acidentes e para a melhoria das condições de trabalho (Russell & Norvig, 2022; Bishop, 2006).

2.3 Gestão de Processos e da Qualidade

A complexidade crescente dos ambientes e as exigências de mercados competitivos e consumidores cada vez mais informados têm levado organizações de diversos setores a repensar os seus modelos de gestão. Neste contexto, a gestão de processos e a da qualidade emergem como pilares estratégicos para o sucesso e a sustentabilidade das

empresas. A integração entre processos internos, produtividade, satisfação do cliente e melhoria contínua tem sido amplamente estudada e aplicada, apoiada por normas internacionais, como a ISO 9001:2015, e por literatura científica e técnica de elevada relevância.

A abordagem de gestão de processos permite visualizar as atividades organizacionais como um conjunto interligado de ações, proporcionando uma visão holística e integrada dos fluxos de trabalho. Por outro lado, a gestão da qualidade centra-se na garantia de que os produtos e serviços cumprem consistentemente os requisitos e as expectativas dos clientes, estimulando a inovação e a eficiência operacional. A convergência destas duas áreas resulta na criação de metodologias robustas e práticas de gestão que não só reduzem custos e desperdícios, como também aumentam a competitividade e a capacidade de adaptação das organizações.

2.3.1 Evolução Histórica e Conceitual da gestão da qualidade

O conceito de qualidade tem raízes históricas que remontam à Revolução Industrial, mas ganhou impulso no século XX com as contribuições de estudiosos como W. Edwards Deming, Joseph M. Juran e Philip Crosby. Deming, por exemplo, enfatizou a importância da melhoria contínua e do controlo estatístico dos processos, defendendo que a qualidade é um investimento que produz resultados a longo prazo. Juran sublinhou a necessidade de planear, controlar e melhorar a qualidade, enquanto Crosby tornou-se conhecido pela máxima de que “a qualidade é gratuita”, destacando a importância de prevenir defeitos antes da sua ocorrência.

Estas ideias pioneiras estabeleceram as bases para os modernos sistemas de gestão da qualidade, as quais foram posteriormente integradas em normas internacionais, nomeadamente a série ISO 9000. Esta família de normas padronizou os requisitos para os sistemas de gestão da qualidade, promovendo a harmonização dos processos e a melhoria contínua a nível global.

2.3.2 Princípios da Gestão da Qualidade

A gestão da qualidade assenta em princípios fundamentais que orientam a estruturação dos sistemas e processos organizacionais, garantindo a eficiência e a satisfação dos clientes. Estes princípios são amplamente reconhecidos na literatura especializada e servem de base para normas internacionais, como a ISO 9001:2015 (*International Organization for Standardization, 2015*).

- Foco no Cliente: A satisfação do cliente é o eixo central da gestão da qualidade. A compreensão das necessidades e expectativas dos clientes permite desenvolver produtos e serviços que agreguem valor e garantam a

fidelização. Segundo Juran (1999), a qualidade deve ser definida pelo cliente, sendo essencial alinhar os processos internos para atender e superar as suas exigências.

- **Liderança:** A liderança desempenha um papel fundamental na criação e manutenção de uma cultura organizacional orientada para a qualidade. Líderes eficazes estabelecem objetivos claros, motivam as equipas e promovem um ambiente propício à inovação e melhoria contínua (Deming, 2000). A capacidade de inspirar e envolver os colaboradores reflete-se diretamente na performance organizacional.
- **Envolvimento das Pessoas:** O compromisso e a participação ativa dos colaboradores são essenciais para o sucesso das iniciativas de qualidade. Organizações que investem na capacitação e valorização dos seus profissionais colhem benefícios como maior produtividade, criatividade e espírito de colaboração. De acordo com Oakland (2014), a gestão da qualidade deve ser uma responsabilidade coletiva, permeando todos os níveis hierárquicos.
- **Abordagem por Processos:** A visão sistémica da organização, entendendo-a como um conjunto de processos interligados, é essencial para uma gestão eficiente. A abordagem por processos permite identificar ineficiências, otimizar fluxos de trabalho e garantir a consistência dos resultados (Hammer & Champy, 2001). Modelos como Business Process Management (BPM) reforçam a necessidade de gerir processos de forma estruturada e orientada para a melhoria contínua.
- **Melhoria Contínua:** A procura permanente pela otimização dos processos, produtos e serviços constitui um princípio fundamental da gestão da qualidade. Ferramentas como o ciclo PDCA (Plan, Do, Check, Act) e metodologias como Seis Sigma e *Lean* são amplamente utilizadas para sustentar essa dinâmica (Pyzdek & Keller, 2018). A melhoria contínua não é apenas uma estratégia de eficiência operacional, mas um fator de competitividade a longo prazo.
- **Tomada de Decisão Baseada em Evidências:** Decisões eficazes devem ser suportadas por dados concretos e análises rigorosas. A gestão da qualidade recorre a indicadores de desempenho, auditorias e monitorização sistemática para assegurar a confiabilidade dos processos e a eficácia das ações implementadas. Segundo Davenport e Harris (2017), organizações orientadas por dados obtêm vantagens estratégicas significativas ao reduzir incertezas e melhorar a precisão das suas decisões.
- **Gestão de Relacionamentos:** O estabelecimento de relações sólidas e mutuamente benéficas com fornecedores, parceiros e clientes é um elemento estratégico da gestão da qualidade. A colaboração e a integração ao longo da

cadeia de valor possibilitam ganhos de eficiência e inovação, promovendo um ambiente de cooperação que resulta em benefícios para todas as partes envolvidas.

Portanto estes princípios estão amplamente documentados em publicações de referência, como as contribuições de Deming (2000), Juran (1999) e Oakland (2014), além de servirem como base para normas e certificações internacionais.

2.3.3 Desenvolvimento da Qualidade em termos de Gestão de Processos

A gestão de processos ganhou relevância com a evolução das abordagens de administração, em resposta à necessidade de aumentar a eficiência e a criação de valor nas organizações. Neste contexto, a Business Process Reengineering, popularizada por Hammer e Champy na década de 1990, destacou a importância de repensar de forma profunda os processos organizacionais, com o objetivo de alcançar melhorias significativas ao nível do desempenho, da qualidade e da produtividade.

Embora centrada em mudanças disruptivas, a Reengenharia de Processos reforçou a centralidade dos processos na gestão organizacional e contribuiu para o desenvolvimento de metodologias que integram sistematicamente os princípios da qualidade. Destacam-se, neste âmbito, o Lean Manufacturing, o Six Sigma e o Business Process Management (BPM), que, apesar de abordagens distintas, partilham o objetivo comum de melhorar o desempenho dos processos. O Lean Manufacturing foca-se na eliminação de desperdícios, o Six Sigma na redução da variabilidade e o BPM na modelação e melhoria contínua dos processos, contribuindo, em conjunto, para o reforço da qualidade, da eficiência operacional e da competitividade organizacional.

2.3.3.1 Gestão de Processos

Um processo pode ser definido como um conjunto de atividades inter-relacionadas que transformam entradas (inputs) em produtos ou serviços (outputs) com valor acrescentado (Dumas et al., 2018). A gestão de processos consiste na identificação, mapeamento, análise, desenho, monitorização e melhoria destes fluxos, garantindo que as organizações operem de forma eficiente e eficaz (ISO, 2015).

A relevância da gestão de processos reside na capacidade de criar uma visão global da organização, permitindo identificar gargalos, reduzir redundâncias e alinhar as atividades com os objetivos estratégicos (Davenport, 1993; Dumas et al., 2018). Num ambiente em constante transformação, a capacidade de adaptar e aperfeiçoar os

processos torna-se um fator de diferenciação competitiva e facilita a integração de novas tecnologias e práticas de gestão, como a automação e a análise de dados em tempo real (Hammer, 2015).

2.3.3.2 Modelos de Gestão de Processos

A gestão de processos desempenha um papel crucial no ambiente empresarial moderno, sendo essencial para a melhoria contínua e a otimização dos fluxos operacionais. Diversos modelos e *frameworks* têm sido desenvolvidos para apoiar a gestão eficaz dos processos organizacionais. Entre os mais relevantes, destacam-se: Ciclo PDCA (Plan, Do, Check, Act): Desenvolvido por W. Edwards Deming, o ciclo PDCA é uma ferramenta fundamental para a melhoria contínua. Este modelo facilita a resolução sistemática de problemas e a melhoria dos processos em quatro fases: planejar (*Plan*), executar (*Do*), verificar (*Check*) e agir (*Act*). A aplicação do ciclo permite uma abordagem iterativa para otimizar processos e atingir melhores resultados ao longo do tempo.

Kaizen: Originário do Japão, o Kaizen enfatiza a melhoria contínua por meio de pequenas e constantes mudanças no processo. Este modelo é amplamente utilizado em ambientes de produção e serviços, sendo eficaz na criação de uma cultura organizacional focada na eliminação de desperdícios e na eficiência dos processos. A filosofia Kaizen promove a participação ativa de todos os colaboradores, tornando cada um responsável por contribuir para a melhoria contínua.

BPMN (*Business Process Model and Notation*): O BPMN é uma notação gráfica padronizada que facilita a modelagem e análise de processos de negócios. Ele visa melhorar a comunicação entre os diversos *stakeholders* e promover a automação e análise dos processos. A padronização proporcionada pelo BPMN torna possível a visualização clara dos processos e a identificação de pontos críticos que necessitam de melhorias.

Six Sigma: A metodologia Six Sigma tem como principal objetivo a redução da variabilidade e a eliminação de defeitos nos processos. Utilizando ferramentas estatísticas, o Six Sigma visa alcançar níveis de desempenho próximos da perfeição. A metodologia é estruturada em torno do ciclo DMAIC (Definir, Medir, Analisar, Melhorar e Controlar), o que garante uma abordagem sistemática para a melhoria da qualidade dos processos.

Lean Manufacturing: foca na eliminação de desperdícios e na maximização do valor para o cliente, com o objetivo de aumentar a eficiência operacional. Este modelo é baseado na identificação de atividades que não agregam valor ao processo e sua eliminação. A literatura de Rother & Shook (2003) oferece uma abordagem complementar que tem sido amplamente aplicada em ambientes de produção e serviços, permitindo a criação de fluxos de trabalho mais ágeis e eficientes.

2.3.4 Abordagens e metodologia da Gestão da Qualidade

A gestão da qualidade tem evoluído ao longo do tempo para responder às mudanças no ambiente empresarial e às crescentes expectativas dos consumidores. Entre as abordagens mais relevantes destacam-se:

Controlo Estatístico de Processos: inicialmente desenvolvido por Walter A. Shewhart e posteriormente popularizado por Deming, utiliza métodos estatísticos para monitorizar e controlar a variabilidade dos processos. A sua aplicação permite a deteção precoce de desvios, possibilitando a implementação de ações corretivas de forma eficiente.

Gestão Total da Qualidade (TQM): uma abordagem holística que envolve todos os níveis da organização na procura pela qualidade. Baseada em princípios como o foco no cliente, o envolvimento dos colaboradores e a melhoria contínua, a TQM visa integrar a qualidade em todas as áreas da empresa, desde a conceção do produto até a entrega final ao cliente.

ISO 9001:2015: é um dos principais referenciais internacionais para a gestão da qualidade. Ela define os requisitos para a implementação de um sistema de gestão da qualidade, garantindo a consistência e a melhoria contínua dos processos organizacionais. A adoção da ISO 9001:2015 visa assegurar que os processos sejam bem estruturados e cumpram com as expectativas dos clientes.

Six Sigma: além do seu foco na redução de defeitos, a metodologia também tem sido amplamente utilizada para reduzir a variabilidade dos processos, integrando ferramentas estatísticas e métodos estruturados que contribuem para a melhoria da qualidade organizacional.

2.3.4.1 Ferramentas de Gestão da Qualidade

A implementação eficaz da gestão da qualidade requer o uso de diversas ferramentas que auxiliam na identificação de problemas, monitorização do desempenho e implementação de melhorias. Entre as ferramentas mais utilizadas, destacam-se:

Ciclo PDCA: como já mencionado, é uma ferramenta essencial para a gestão de projetos de melhoria contínua, permitindo uma abordagem sistemática na resolução de problemas e no aprimoramento dos processos.

Diagrama de Ishikawa (ou Diagrama de Causa e Efeito): uma ferramenta visual que facilita a identificação das causas raízes de problemas, agrupando fatores que possam contribuir para falhas no processo. Essa abordagem ajuda a organizar as causas potenciais e orientar as ações corretivas necessárias.

Histogramas e Gráficos de Controlo: essas ferramentas são utilizadas para monitorizar a variabilidade dos processos. Através de análises estatísticas, é possível detetar desvios e tomar ações corretivas antes que problemas maiores ocorram.

Análise de Pareto: é uma ferramenta que ajuda a priorizar problemas, evidenciando os fatores que contribuem de forma mais significativa para os efeitos indesejados. Baseada no princípio de que 80% dos problemas decorrem de 20% das causas, essa análise facilita a alocação de recursos para a resolução dos problemas mais críticos.

Metodologia 5S: Desenvolvida no Japão, a metodologia 5S objetiva organizar o ambiente de trabalho de forma eficaz. Seus princípios (*Seiri, Seiton, Seiso, Seiketsu e Shitsuke*) visam melhorar a eficiência, a segurança e a melhoria contínua, criando um ambiente de trabalho mais produtivo e seguro.

FMEA (Análise dos Modos de Falha e dos Efeitos): uma ferramenta preventiva que permite identificar e avaliar possíveis falhas nos processos antes que elas ocorram. Através da análise dos modos de falha e seus efeitos, é possível implementar medidas corretivas para evitar que os problemas se agravem, melhorando a robustez dos processos.

2.3.4.2 Indicadores de Desempenho e Melhoria Contínua

A definição e monitorização de indicadores de desempenho são cruciais para a gestão da qualidade, uma vez que permitem medir os resultados das ações implementadas e identificar oportunidades de melhoria. Os principais indicadores de desempenho na gestão de processos incluem a Taxa de Defeitos, que mede a frequência de falhas em um período ou lote de produção, e o Tempo de Ciclo, que avalia o tempo total necessário para concluir um processo, ajudando a identificar gargalos. A Satisfação do Cliente é crucial, pois indicadores e feedbacks alinham os processos às expectativas do mercado. O Índice de Conformidade avalia a aderência dos processos aos padrões e normas estabelecidas, enquanto o Custo da Qualidade analisa os custos envolvidos na prevenção, avaliação e correção de defeitos, fornecendo uma visão dos impactos financeiros das ações de qualidade. A combinação de indicadores quantitativos e qualitativos oferece uma visão abrangente do desempenho organizacional, permitindo ajustes dinâmicos e a promoção de uma cultura de melhoria contínua. Estudos recentes têm demonstrado que organizações que investem em sistemas integrados de indicadores tendem a alcançar melhores resultados em termos de eficiência e satisfação do cliente, Oakland, J. S. (2014).

2.3.5 Integração entre Gestão de Processos e da Qualidade

A integração entre a gestão de processos e a qualidade revela-se fundamental para a obtenção de resultados superiores. Enquanto a gestão de processos fornece a estrutura, o mapeamento e o acompanhamento das atividades organizacionais, a gestão da qualidade assegura que estas atividades sejam executadas de acordo com padrões rigorosos e orientados para a satisfação do cliente.

Esta sinergia permite às organizações reduzir custos operacionais, aumentar a produtividade, melhorar a qualidade dos produtos e serviços e fomentar a inovação. Adotar uma abordagem integrada significa dispor de mecanismos que permitam a detecção precoce de desvios e a implementação de ações corretivas de forma rápida e eficaz.

A integração entre a gestão de processos e a qualidade constitui um dos pilares essenciais para a competitividade e a sustentabilidade das organizações no contexto global atual. Ao alinhar a estruturação, o mapeamento e a monitorização dos processos com elevados padrões de qualidade, as empresas conseguem reduzir custos, eliminar desperdícios e fomentar a inovação. A evolução histórica destes conceitos, alicerçada nas contribuições de estudiosos como Deming, Juran e Crosby, e a consolidação de normas internacionais como a ISO 9001:2015, demonstram que os modelos de gestão integrados são determinantes para a transformação da cultura organizacional.

2.3.6 Desafios na Implementação

A implementação de sistemas integrados de gestão de processos e qualidade, apesar dos benefícios evidentes, enfrenta diversos desafios. Entre eles, destaca-se a resistência à mudança, pois a cultura organizacional pode dificultar a adoção de novas práticas e a modificação de processos estabelecidos. Além disso, a necessidade de investimento inicial em recursos financeiros, tempo e formação é um obstáculo significativo. A integração de sistemas também pode ser complexa, exigindo uma infraestrutura tecnológica robusta e uma gestão eficiente dos dados. Por fim, a sustentação da melhoria contínua após a implementação inicial é desafiadora, pois é necessária uma monitorização constante e um forte comprometimento da liderança para evitar a estagnação dos processos (Oakland, 2014).

Em suma, a gestão de processos e a qualidade, quando implementadas de forma estratégica e integrada, transcendem a mera ferramenta de melhoria operacional, constituindo um diferencial competitivo determinante para o sucesso organizacional, a inovação e a sustentabilidade num mercado cada vez mais exigente.

2.4 Modelos e Tecnologias de IA Aplicadas na indústria

2.4.1 *Machine Learning*

O Machine Learning (ML), ou aprendizagem automática, constitui uma das áreas mais relevantes e estruturantes da IA, sendo dedicado ao desenvolvimento de sistemas capazes de aprender a partir de dados e de melhorar o seu desempenho sem necessidade de programação explícita para cada tarefa. O princípio fundamental do

ML assenta na capacidade dos algoritmos identificarem padrões e relações subjacentes em grandes volumes de dados, ajustando os seus parâmetros com base na experiência acumulada, com vista à melhoria progressiva dos resultados obtidos (Mitchell, 1997; Alpaydin, 2021). Esta capacidade de adaptação pode conferir ao ML um papel central em múltiplos domínios de aplicação, incluindo a indústria transformadora, a saúde, as finanças e o setor energético.

Um conceito central no ML é o da generalização, entendida como a capacidade de um modelo aprender a partir de dados históricos e aplicar esse conhecimento a novos dados, mantendo um desempenho fiável. A generalização distingue modelos meramente descritivos de modelos efetivamente úteis para apoio à decisão, sendo um critério essencial para a sua aplicação em contexto organizacional (Bishop & Nasrabadi, 2023). No âmbito da Indústria 4.0 e da crescente digitalização dos processos produtivos, o ML tem-se afirmado como uma ferramenta fundamental para lidar com a complexidade, a variabilidade e a heterogeneidade dos sistemas industriais, permitindo extrair conhecimento acionável a partir de fontes de dados diversas e, em muitos casos, em tempo quase real (Jordan & Mitchell, 2015).

O desenvolvimento de um modelo de ML corresponde a um processo iterativo que integra contributos da ciência dos dados, da estatística e da engenharia de sistemas. Este processo inicia-se com a recolha e preparação dos dados, etapa crítica para garantir a sua qualidade, integridade e representatividade. Segue-se a seleção do algoritmo mais adequado ao problema em análise, que pode variar desde modelos estatísticos simples até arquiteturas baseadas em redes neuronais profundas. Durante a fase de treino, o modelo ajusta os seus parâmetros a partir dos dados disponíveis, procurando minimizar uma função de erro previamente definida (Goodfellow et al., 2016; Géron, 2023). Após o treino, o desempenho do modelo é avaliado através de métricas estatísticas apropriadas, como *accuracy*, *precision*, *recall* ou erro quadrático médio, consoante se trate de problemas de classificação ou de regressão (Raschka et al., 2022).

Uma vez validado, o modelo é implementado em ambiente produtivo, onde deve ser continuamente monitorizado e, sempre que necessário, atualizado. Esta monitorização é particularmente relevante para mitigar o impacto de alterações nos dados ou no contexto operacional, fenómeno conhecido como *concept drift*, que pode conduzir à degradação progressiva do desempenho do modelo ao longo do tempo (Gama et al., 2020).

Do ponto de vista conceptual, os algoritmos de ML organizam-se em três grandes paradigmas de aprendizagem: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço (Marsland, 2020; Sutton & Barto, 2018). A aprendizagem supervisionada baseia-se em dados rotulados, sendo amplamente utilizada em tarefas de previsão, classificação e controlo de qualidade automatizado. A

aprendizagem não supervisionada aplica-se a dados sem rótulos, tendo como objetivo a descoberta de estruturas latentes, padrões ou agrupamentos, sendo particularmente útil em análises exploratórias e segmentação. Por sua vez, a aprendizagem por reforço envolve a interação de um agente com o ambiente, aprendendo por tentativa e erro através de um sistema de recompensas, sendo aplicada em problemas de controlo, otimização e gestão adaptativa de sistemas. Nas últimas décadas, os avanços no deep learning e na aprendizagem por reforço impulsionaram uma transformação significativa no campo do ML, permitindo o processamento eficaz de dados não estruturados, como imagens, sinais e texto, com níveis de desempenho anteriormente difíceis de alcançar. A integração destas técnicas em sistemas industriais complexos tem possibilitado melhorias relevantes ao nível da eficiência operacional, da fiabilidade e da sustentabilidade, sobretudo em contextos caracterizados por elevados volumes de dados e exigências de resposta rápida (Bengio, 2022; Silver et al., 2021).

Para o desenvolvimento de um modelo de ML de forma organizada, segue as seguintes etapas:

- 1º Passo: recolha e pré-processamento de dados para garantir a qualidade das informações;
- 2º Passo: Escolha do algoritmo de aprendizado apropriado para o problema;
- 3º Passo: Treinamento do modelo utilizando dados históricos;
- 4º Passo: Avaliação do desempenho por meio de métricas estatísticas;
- 5º Passo: Implementação e manutenção do modelo;

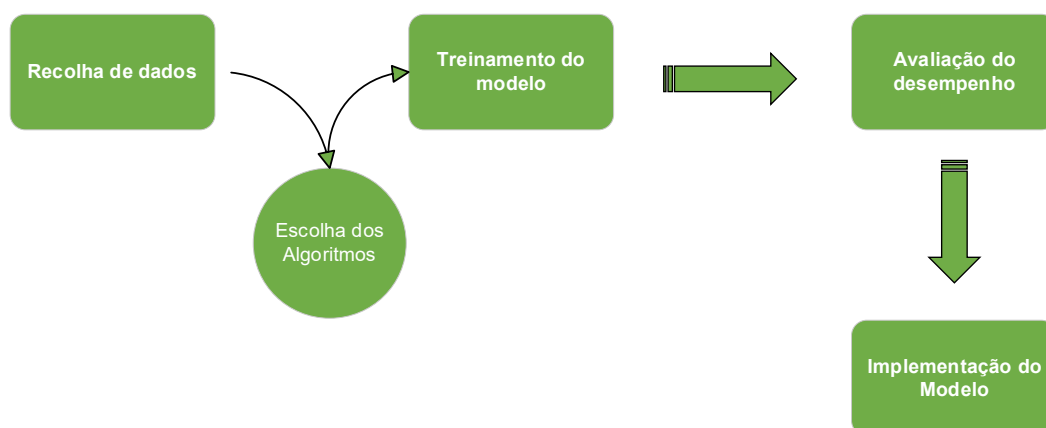


Figura 2.2 - Etapas de um Modelo ML. Fonte: Elaboração própria.

A Tabela 2.1 abaixo, compara algumas características essenciais de algoritmos ML, que facilita a escolha do modelo adequado para diferentes tarefas:

Tabela 2.1 - Comparação de algoritmos ML

Algoritmo	Tipo de Aprendizagem	Aplicações Comuns	Vantagens	Desvantagens
Regressão Linear	Supervisionado	Predição de valores contínuos	Simples, rápido de treinar	Não adequado para relações não lineares
SVM	Supervisionado	Classificação, detecção de anomalias	Bom desempenho em alta dimensionalidade	Difícil de interpretar, lento para grandes datasets
K-means	Não supervisionado	Agrupamento de dados	Rápido e eficiente	Sensível à escolha inicial de k
Q-learning	Reforço	Jogos, sistemas autônomos	Pode aprender estratégias complexas	Requer muitos recursos computacionais

Em paralelo, a comunidade científica tem enfatizado a importância de tornar os modelos de ML mais transparentes e interpretáveis. Surge, assim, o conceito de aprendizagem automática explicável, conhecido como *Explainable Artificial Intelligence* (XAI), que visa permitir a compreensão das decisões produzidas pelos algoritmos. A explicabilidade tornou-se um requisito crítico para a aceitação da IA em setores regulados, não só pela necessidade de conformidade ética e legal, mas também pela confiança que os decisores devem depositar nas recomendações dos sistemas inteligentes (Miller, 2019; Arrieta et al., 2020; Barredo Arrieta & del Ser, 2023).

2.4.2 Deep Learning (DL)

O Deep Learning (DL), ou aprendizagem profunda, constitui uma das vertentes mais avançadas da IA, sendo responsável por progressos significativos em tarefas de elevada complexidade associadas à percepção, à análise de dados e à tomada de decisão automática. O DL pode ser entendido como uma evolução do Machine Learning, distinguindo-se pela utilização de redes neuronais artificiais com múltiplas camadas, capazes de aprender representações hierárquicas dos dados. Estas representações permitem que o sistema extraia automaticamente características relevantes em diferentes níveis de abstração, reduzindo a necessidade de definição manual de atributos (feature engineering) (LeCun et al., 2015; Goodfellow et al., 2016).

Do ponto de vista conceptual, o DL baseia-se na modelação matemática e computacional de mecanismos inspirados no funcionamento do cérebro humano, embora de forma altamente simplificada. As redes neuronais artificiais são constituídas por unidades de processamento designadas por neurónios, organizadas em camadas de entrada, camadas ocultas e camadas de saída. Cada neurónio recebe sinais de entrada, aplica uma transformação linear seguida de uma função de ativação não linear e transmite o resultado à camada seguinte. Esta estrutura permite a combinação progressiva de padrões simples em representações mais complexas, sendo particularmente eficaz no tratamento de dados extensos, não estruturados ou de elevada dimensionalidade, como imagens, sinais de áudio e texto (Schmidhuber, 2022; Bengio, 2022).

O processo de aprendizagem de um modelo de DL segue um ciclo iterativo que envolve a propagação direta (forward propagation) dos dados através da rede, o cálculo do erro entre as previsões do modelo e os valores reais, e a retropropagação (backpropagation) desse erro. A retropropagação permite ajustar os pesos das ligações entre neurónios com o objetivo de minimizar uma função de custo previamente definida. Este procedimento é repetido ao longo de múltiplas iterações, ou épocas de treino, até que o modelo atinja um desempenho considerado adequado (Goodfellow et al., 2016). A eficácia do modelo depende de diversos fatores, nomeadamente da quantidade e qualidade dos dados disponíveis, da arquitetura da rede e dos algoritmos de otimização utilizados, como métodos baseados em gradiente descendente adaptativo (Kingma & Ba, 2015).

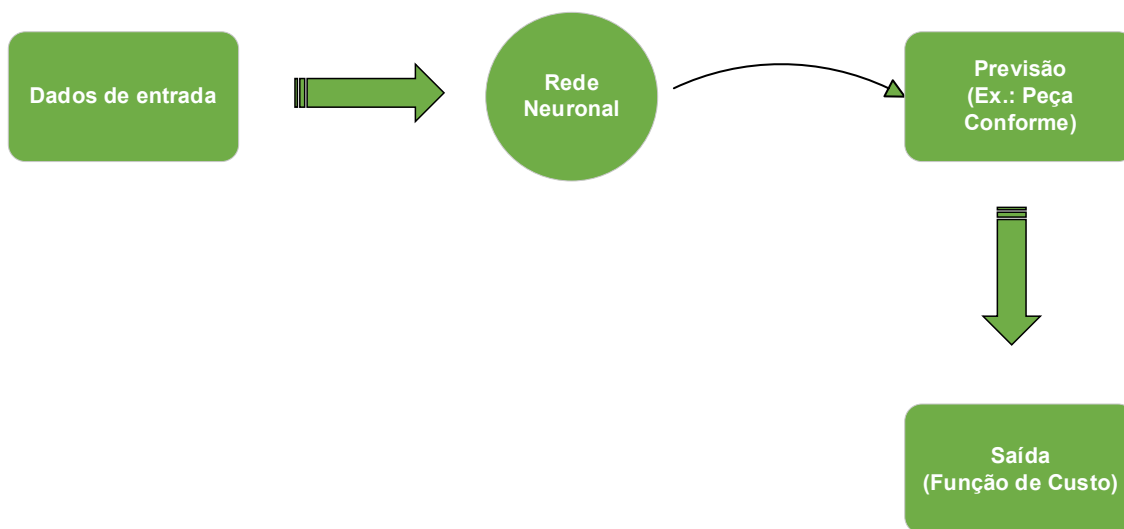


Figura 2.3 - Processo de treino de um algoritmo de Deep Learning.

Fonte: Elaboração própria

A Figura 2.3 ilustra o funcionamento conceptual de um processo de treino em DL. Os dados de entrada são submetidos à rede neuronal, que processa a informação através de múltiplas camadas até gerar uma previsão. A diferença entre o valor previsto e o

valor real é calculada por uma função de custo, cujo resultado é utilizado na retro propagação para ajustar os pesos sinápticos e reduzir o erro global. Este ciclo repete-se de forma iterativa até atingir a precisão desejada.

As arquiteturas de DL podem assumir diversas formas, adaptando-se à natureza dos dados e aos objetivos da tarefa. As Redes Neurais Convolucionais (CNNs) são amplamente utilizadas para o processamento de imagens e vídeos, destacando-se pela sua capacidade de identificar padrões espaciais e visuais; as RNNs e as suas variantes, como as Long Short-Term Memory (LSTM), são adequadas à análise de dados temporais e sequenciais, como séries de sensores ou registos de produção; os *Autoencoders* são aplicados à deteção de anomalias e à redução de dimensionalidade; e as Redes Geradoras *Adversariais* (GANs), formadas por duas redes em competição, permitem gerar novos dados sintéticos, úteis em simulações e treino de modelos (Karras et al., 2021).

A Tabela 2.2 sintetiza as principais arquiteturas de redes neuronais profundas, destacando as suas características técnicas e áreas de aplicação mais comuns.

Tabela 2.2 - Principais arquiteturas de redes neuronais profundas e respetivas aplicações.

Arquitetura	Descrição técnica	Domínios de aplicação
CNN	Estrutura com camadas convolucionais e filtros para extração automática de características espaciais.	Reconhecimento de imagens, visão computacional, controlo de qualidade e deteção de anomalias.
RNN	Integra memória temporal que permite o processamento sequencial de dados.	Análise de séries temporais, previsão de falhas e manutenção preditiva.
LSTM / GRU	Versões otimizadas das RNNs que superam o problema do desaparecimento do gradiente.	Modelação de processos contínuos e previsões em tempo real.
Autoencoder	Rede que aprende representações comprimidas dos dados através da reconstrução das entradas.	Deteção de anomalias, compressão e pré-processamento de dados.
GAN	Duas redes competem entre si: uma gera dados sintéticos e a outra avalia a sua autenticidade.	Simulações, geração de imagens e reforço de bases de dados para treino.

Do ponto de vista organizacional e científico, o *Deep Learning* tem-se afirmado como uma tecnologia de suporte essencial à Indústria 4.0, potenciando sistemas de controlo inteligente, inspeção automatizada e análise preditiva. A sua integração com a Internet das Coisas (IoT), *Edge Computing* e Digital Twins permite a monitorização contínua e a tomada de decisão em tempo real, promovendo a eficiência, a rastreabilidade e a sustentabilidade dos processos industriais (Lee, Bagheri & Kao, 2014).

2.4.3 Processamento de Linguagem Natural (PLN)

O Processamento de Linguagem Natural (PLN) constitui uma das áreas mais relevantes e de crescimento mais acelerado da IA, sendo dedicado ao

desenvolvimento de métodos que permitam aos sistemas computacionais compreender, interpretar, processar e gerar linguagem humana, tanto em formato textual como oral. O objetivo central do PLN é possibilitar interações homem-máquina em linguagem natural, aproximando o comportamento dos sistemas computacionais dos mecanismos de comunicação humana (Jurafsky & Martin, 2023).

Do ponto de vista histórico, o PLN evoluiu de abordagens iniciais baseadas em regras linguísticas e sintáticas explícitas para métodos estatísticos e, mais recentemente, para modelos neuronais profundos. Esta evolução foi impulsionada pelo aumento da capacidade computacional e pela disponibilidade de grandes volumes de dados textuais, fatores que permitiram o treino de modelos cada vez mais complexos e sensíveis ao contexto (Young et al., 2018). A introdução de técnicas de aprendizagem automática e aprendizagem profunda representou um ponto de viragem, ao permitir que os sistemas aprendessem padrões linguísticos diretamente a partir dos dados, sem necessidade de especificação manual de regras.

Um contributo fundamental para esta evolução foi o desenvolvimento de representações vetoriais da linguagem, conhecidas como word embeddings. Modelos como o Word2Vec e o GloVe permitiram mapear palavras para vetores num espaço multidimensional, de forma a capturar relações semânticas e sintáticas com base em padrões de coocorrência observados em grandes corpora textuais (Mikolov et al., 2013; Pennington et al., 2014). Estas representações constituíram a base para avanços subsequentes em tarefas de análise semântica e classificação de texto.

O avanço estrutural mais significativo no PLN moderno ocorreu com a introdução da arquitetura Transformer, baseada em mecanismos de atenção, que substituiu as redes recorrentes tradicionais e passou a permitir a modelação eficaz de dependências de longo alcance em sequências linguísticas (Vaswani et al., 2017). Esta arquitetura deu origem aos denominados Modelos de Linguagem de Grande Escala (Large Language Models – LLMs), como o BERT, o GPT e o T5, que se tornaram a base das aplicações contemporâneas de IA conversacional e análise semântica avançada (Devlin et al., 2019; Brown et al., 2020; Raffel et al., 2020). Estes modelos são pré-treinados em grandes coleções de texto e posteriormente ajustados a tarefas específicas, apresentando elevado desempenho em tradução automática, sumarização, classificação de sentimentos e resposta automática a perguntas.

Do ponto de vista técnico, os sistemas de PLN recorrem a um conjunto de etapas de pré-processamento, que podem incluir tokenização, lematização, normalização textual e remoção de ruído, seguidas de técnicas de análise semântica e pragmática. Estas etapas permitem compreender não apenas o significado literal das palavras, mas também o contexto e a intenção subjacente ao discurso, aumentando a robustez das aplicações em cenários reais (Jurafsky & Martin, 2023; Cambria et al., 2022).

A Tabela 2.3 sintetiza os principais modelos linguísticos de referência, destacando as suas características e contribuições para o desenvolvimento do PLN moderno.

Tabela 2.3 - Principais modelos e arquiteturas de PLN.

Modelo	Ano / Arquitetura	Características Técnicas	Principais Aplicações
Word2Vec	2013 / Rede neuronal rasa	Representação vetorial de palavras com base em coocorrência.	Análise semântica e extração de características textuais.
GloVe	2014 / Estatístico	Combina coocorrências globais e locais de palavras.	Análise de sentimentos e agrupamento semântico.
ELMo	2018 / RNN bidirecional	Contextualiza o significado das palavras conforme o contexto da frase.	Reconhecimento de entidades, classificação de texto.
BERT	2019 / Transformer	Modelo bidirecional pré-treinado em grandes corpora; sensível ao contexto.	Extração de informação, pesquisa semântica, QA (<i>question answering</i>).
GPT-3 / GPT-4	2020–2023 / Transformer unidirecional	Modelo generativo de larga escala treinado em linguagem natural.	Resumo, diálogo, tradução e apoio à decisão textual.
T5	2020 / Seq2Seq Transformer	Formula todas as tarefas linguísticas como problemas de tradução.	Tradução, sumarização, classificação, QA.

O impacto do PLN na transformação digital das organizações revela-se particularmente significativo em contextos caracterizados por elevados volumes de informação textual. As ferramentas baseadas em PLN permitem automatizar a análise de dados qualitativos, converter texto não estruturado em indicadores quantitativos e apoiar a sistematização e disseminação do conhecimento organizacional, contribuindo para decisões mais informadas e consistentes (Young et al., 2018; Cambria et al., 2022). Estas capacidades assumem especial relevância na gestão da qualidade e dos processos, ao possibilitarem a identificação de ineficiências, a deteção precoce de padrões associados a reclamações ou não conformidades e a implementação mais célere de ações corretivas.

A convergência entre o PLN, o ML e o DL tem impulsionado o desenvolvimento de sistemas inteligentes de apoio à decisão, capazes de interpretar contextos técnicos e terminologia especializada, como normas ISO, procedimentos de auditoria e relatórios de desempenho. Esta evolução sustenta a nova geração de sistemas de gestão do conhecimento baseados em IA, alinhados com os princípios da Indústria 4.0 e da Gestão da Qualidade Total (TQM), ao promoverem uma integração mais eficaz entre informação, processos e tomada de decisão.

Apesar dos avanços alcançados, o PLN enfrenta desafios relevantes relacionados com a explicabilidade, a ética e o viés algorítmico. A literatura recente evidencia que os modelos de linguagem de grande escala podem reproduzir enviesamentos presentes nos dados de treino e gerar interpretações ambíguas ou incorretas, o que reforça a necessidade de mecanismos de auditoria algorítmica e de governação

responsável destes sistemas (Bender et al., 2021; Bommasani et al., 2022). Neste enquadramento, a evolução do PLN deve equilibrar inovação técnica e responsabilidade ética, assegurando a fiabilidade, a transparência e a equidade das soluções linguísticas aplicadas em contexto organizacional.

2.4.4 Visão Computacional

A Visão Computacional constitui um dos domínios mais consolidados e de maior impacto da IA, sendo dedicada ao desenvolvimento de métodos que permitam aos sistemas computacionais adquirir, analisar e interpretar informação visual proveniente do mundo real. O seu objetivo central consiste em possibilitar que máquinas e sistemas extraiam significado de imagens e vídeos de forma funcionalmente análoga à perceção humana, convertendo dados visuais em informação quantificável e acionável para apoio à decisão (Szeliski, 2022; Ballard & Brown, 1982).

A evolução da visão computacional esteve historicamente associada ao desenvolvimento de técnicas determinísticas de processamento de imagem, incluindo operações de filtragem, segmentação e deteção de contornos. Contudo, o surgimento e a consolidação dos paradigmas de ML e, em particular, de DL, transformaram profundamente este domínio. As redes neuronais convolucionais (CNNs) introduziram mecanismos de aprendizagem hierárquica de características visuais diretamente a partir dos dados, permitindo a deteção automática de padrões complexos e reduzindo significativamente a dependência da definição manual de regras e parâmetros (LeCun et al., 2015; Krizhevsky et al., 2017).

Do ponto de vista funcional, a arquitetura de um sistema de visão computacional pode ser descrita através de quatro etapas fundamentais. A primeira corresponde à aquisição de imagem, na qual sensores e câmaras industriais captam dados visuais em diferentes espectros, como o visível, o infravermelho ou o ultravioleta. Segue-se a fase de pré-processamento, que envolve operações de normalização, filtragem e melhoria de contraste com o objetivo de aumentar a qualidade e a robustez das imagens analisadas. A etapa de extração de características recorre a redes neuronais convolucionais ou a abordagens híbridas para identificar formas, texturas, cores e padrões relevantes. Por fim, a fase de decisão automatizada utiliza algoritmos de classificação ou deteção para avaliar conformidades, identificar defeitos ou detetar anomalias em processos produtivos (Szeliski, 2022).



Figura 2.4 - Estrutura genérica de um sistema de Visão Computacional. Fonte: Elaboração própria

O Figura 2.4 ilustra o funcionamento conceptual de um sistema de visão computacional, evidenciando as principais etapas do processamento da informação visual. O processo inicia-se com a aquisição de imagem, realizada através de câmaras ou sensores industriais. Segue-se a fase de pré-processamento, que envolve operações de filtragem, normalização e melhoria da qualidade das imagens, com o objetivo de reduzir ruído e aumentar a robustez da análise. Na etapa de extração de características, redes neurais convolucionais identificam automaticamente padrões visuais relevantes, tais como formas, texturas ou variações cromáticas. Por fim, a fase de interpretação e decisão automática permite classificar os resultados, por exemplo, em conformes ou não conformes, gerando indicadores de qualidade que apoiam a monitorização e o controlo dos processos produtivos.

A literatura recente reconhece a visão computacional como um elemento estruturante da Indústria 4.0, ao integrar sensores inteligentes, técnicas de IA e mecanismos de análise em tempo real nos sistemas produtivos (European Commission, 2021; NIST, 2023). No contexto das fábricas inteligentes (smart factories), as câmaras industriais e os algoritmos de análise visual desempenham um papel central em atividades de inspeção automatizada, monitorização contínua da qualidade, metrologia digital e manutenção preditiva, permitindo decisões mais rápidas e fundamentadas em evidência visual. De acordo com a European Association for Artificial Intelligence (EurAI, 2023), a adoção destas tecnologias contribui para o reforço da competitividade e da sustentabilidade industrial, ao reduzir desperdícios e melhorar a rastreabilidade dos produtos ao longo da cadeia de valor.

Os avanços mais recentes em visão computacional estão fortemente associados à combinação de Deep Learning com técnicas de Edge Computing, que possibilitam o processamento descentralizado e em tempo real diretamente nos equipamentos ou na proximidade da fonte de dados. Esta abordagem revela-se particularmente relevante em setores industriais e na área da saúde, onde requisitos de baixa latência, fiabilidade e segurança da informação são críticos (Chen et al., 2023; NIST, 2023). Paralelamente, a crescente preocupação com a ética, a transparência e a responsabilização dos sistemas de IA tem impulsionado o desenvolvimento do conceito de Visão Computacional Explicável (Explainable Computer Vision – XCV), cujo objetivo é tornar os modelos visuais mais interpretáveis e auditáveis. Esta linha de investigação está alinhada com os princípios do AI Act da União Europeia, promovendo a confiança e a conformidade regulatória na aplicação de sistemas de

visão computacional em contextos organizacionais e industriais (European Commission, 2021; Barredo Arrieta & del Ser, 2023). A Tabela 2.4 mostra principais técnicas de Visão computacional.

Tabela 2.4 - Principais técnicas e aplicações de Visão Computacional.

Técnica / Tecnologia	Descrição técnica	Domínios de aplicação
Processamento clássico de imagem	Métodos determinísticos de filtragem, segmentação e deteção de contornos.	Pré-processamento e medição dimensional.
Redes Neurais Convolucionais (CNNs)	Extraem características visuais de forma automática e hierárquica.	Inspeção de qualidade, reconhecimento de padrões e controlo de processos.
<i>Transfer Learning</i>	Adaptação de redes pré-treinadas (ex. <i>ResNet</i> , <i>EfficientNet</i>) a novos contextos.	Inspeção industrial, reconhecimento de falhas e manutenção.
Visão 3D e reconstrução volumétrica	Análise geométrica e espacial com base em câmaras estéreo e sensores LIDAR.	Robótica industrial, metrologia e fabrico aditivo.
Visão Hiperespectral e Térmica	Utilização de espectros invisíveis ao olho humano para análise avançada.	Monitorização de temperatura, deteção de defeitos internos e inspeção de materiais.
Visão Computacional Explicável (XCV)	Combina precisão algorítmica com interpretabilidade e auditoria ética.	Controlo regulatório, auditoria de IA e conformidade com o AI Act.

A visão computacional assume um papel fundamental no enquadramento da Gestão da Qualidade Total (TQM) e do Controlo Estatístico de Processos (SPC), ao possibilitar a recolha sistemática e automática de dados visuais e o seu tratamento estatístico em tempo real. A utilização destes sistemas reduz a subjetividade inerente às inspeções manuais, aumenta a consistência dos resultados e reforça a fiabilidade da avaliação da conformidade dos processos e produtos. Desta forma, contribui para a consolidação de uma cultura organizacional orientada para a tomada de decisão baseada em dados (data-driven decision making), elemento central dos modelos modernos de gestão da qualidade (Oakland, 2014; Pyzdek & Keller, 2018).

Paralelamente, as aplicações mais recentes de visão computacional encontram-se progressivamente integradas em modelos de gestão inteligente de processos (Smart Process Management), nos quais a IA atua de forma articulada com sistemas ciberfísicos e plataformas de Business Process Management (BPM). Esta convergência entre perceção visual automatizada, automação de processos e análise preditiva traduz-se em melhorias significativas ao nível da eficiência operacional, da rastreabilidade e da sustentabilidade dos sistemas produtivos. Tal evolução encontra-se alinhada com as orientações estratégicas da Comissão Europeia e do NIST para a Indústria 4.0, que preconiza uma indústria mais centrada no ser humano, sustentável e resiliente (European Commission, 2023; NIST, 2023).

2.4.5 Sistemas Especialistas e Robótica Inteligente

Os Sistemas Especialistas e a Robótica Inteligente constituem duas vertentes históricas da IA que, apesar de terem origens distintas, partilham o objetivo comum de reproduzir computacionalmente capacidades humanas de raciocínio, tomada de decisão e ação em ambientes complexos. Ambas contribuem de forma significativa para a automação cognitiva e operacional dos processos organizacionais, assumindo um papel relevante no contexto da transformação digital da indústria (Russell & Norvig, 2021; Bekey, 2023).

Sistemas Especialistas

Os Sistemas Especialistas correspondem a aplicações computacionais concebidas para simular o processo de decisão de um especialista humano num domínio específico do conhecimento. A sua arquitetura clássica baseia-se num motor de inferência que opera sobre uma base de conhecimento, constituída por factos, regras e heurísticas, frequentemente formuladas sob a lógica “se... então...”. Este mecanismo permite ao sistema inferir conclusões a partir da informação disponível e, simultaneamente, justificar o raciocínio seguido, reforçando a transparência das decisões (Giarratano & Riley, 2020).

Os primeiros sistemas especialistas surgiram nas décadas de 1970 e 1980, destacando-se exemplos como o MYCIN, no diagnóstico médico, e o XCON, na configuração de sistemas computacionais. Embora inicialmente limitados pela rigidez das regras, estes sistemas evoluíram para abordagens híbridas, integrando técnicas de Machine Learning e de Processamento de Linguagem Natural, o que lhes confere maior flexibilidade, adaptabilidade e capacidade de aprendizagem a partir de dados (Camarinha-Matos & Ferrada, 2021).

Em contexto organizacional, os sistemas especialistas têm aplicação direta na gestão da qualidade e na gestão de processos, funcionando como sistemas de apoio à decisão em ambientes caracterizados por elevada complexidade e requisitos normativos rigorosos. Podem ser utilizados para avaliar a conformidade com normas ISO, apoiar auditorias da qualidade, sugerir ações corretivas, recomendar planos de manutenção preventiva ou analisar desvios em processos produtivos (Oakland, 2014; Juran & Godfrey, 1999). No âmbito da Indústria 4.0, estes sistemas integram-se com sensores e plataformas de dados em tempo real, contribuindo para o desenvolvimento de Sistemas de Apoio à Decisão Inteligente (IDSS), capazes de operar com conhecimento contextual dinâmico (Ragavan et al., 2022).

A principal vantagem dos sistemas especialistas reside na formalização e preservação do conhecimento tácito dos peritos humanos, assegurando consistência e

continuidade na tomada de decisão, mesmo na ausência de especialistas experientes (Marcus & Davis, 2020).

Robótica Inteligente

A Robótica Inteligente representa a materialização física dos princípios da IA, combinando percepção, planeamento, raciocínio e ação em sistemas autónomos capazes de interagir de forma adaptativa com o ambiente e com os seres humanos. A sua evolução tem sido impulsionada pela integração de sensores inteligentes, visão computacional, algoritmos de aprendizagem automática e técnicas avançadas de controlo (Siciliano & Khatib, 2023).

Ao contrário dos robôs industriais tradicionais, programados para executar tarefas fixas e repetitivas, os robôs inteligentes distinguem-se pela sua capacidade cognitiva, que lhes permite aprender com a experiência, adaptar o comportamento a contextos dinâmicos e tomar decisões em ambientes incertos. Estas capacidades são frequentemente suportadas por arquiteturas híbridas, nas quais módulos de percepção visual e tátil são combinados com mecanismos de raciocínio lógico e aprendizagem automática (Bekey, 2023; Thrun et al., 2022).

No contexto industrial, a robótica inteligente assume um papel central na Indústria 4.0 e na transição para a Indústria 5.0, ao viabilizar a colaboração segura entre humanos e máquinas — a denominada cobótica (collaborative robotics). Estes sistemas colaborativos ampliam as capacidades humanas em tarefas repetitivas, perigosas ou de elevada precisão, promovendo maior flexibilidade, segurança e eficiência operacional (European Commission, 2023; NIST, 2023).

Do ponto de vista da gestão da qualidade, os robôs inteligentes desempenham funções essenciais na inspeção automatizada, na manipulação de componentes sensíveis e na medição tridimensional de produtos, assegurando padrões de qualidade consistentes e rastreáveis. A integração entre robótica e machine vision permite ainda a monitorização contínua da qualidade ao longo do processo produtivo, reduzindo desperdícios e evitando paragens não planeadas.

Na gestão de processos, a robótica inteligente tem impulsionado a automação de tarefas administrativas através da Robotic Process Automation (RPA), que evoluiu para formas mais avançadas e cognitivas (Intelligent RPA). Esta convergência entre robótica e IA possibilita a análise e execução de fluxos de trabalho complexos com base em regras, padrões e dados históricos, contribuindo para ganhos significativos de eficiência, consistência e fiabilidade dos processos organizacionais (Syed et al., 2020; Ragavan et al., 2022).

2.4.6 Chatbots e Assistentes Virtuais

Os chatbots e os assistentes virtuais inteligentes constituem uma das aplicações mais visíveis da IA no domínio da comunicação e da gestão organizacional. Estas tecnologias combinam Processamento de Linguagem Natural (PLN), *Machine Learning* e reconhecimento de fala, permitindo interações homem-máquina em linguagem natural, com respostas contextuais e coerentes (Adamopoulou & Moussiades, 2020; Jurafsky & Martin, 2023).

Conceptualmente, um chatbot é um sistema de software concebido para interagir com utilizadores através de texto ou voz, executando tarefas automatizadas ou fornecendo informação. Os assistentes virtuais distinguem-se por integrarem capacidades cognitivas mais avançadas, como a compreensão do contexto, a aprendizagem com a experiência e a integração com outros sistemas empresariais, o que lhes permite desempenhar funções mais complexas no suporte às atividades organizacionais (Hoy, 2018; Følstad & Skjuve, 2021).

A arquitetura de um chatbot moderno assenta, de forma geral, em três componentes fundamentais: um módulo de compreensão da linguagem natural (NLU), responsável por identificar intenções e entidades; um motor de diálogo, que gere o fluxo da interação; e um módulo de geração de linguagem natural (NLG), encarregue de produzir respostas adequadas ao contexto. Estes módulos são suportados por algoritmos de aprendizagem automática, permitindo a adaptação progressiva do sistema ao perfil e às necessidades dos utilizadores (Klopfenstein et al., 2017; Adamopoulou & Moussiades, 2020).

Os avanços recentes em modelos de linguagem de grande escala (LLMs), baseados em arquiteturas Transformer, contribuíram para melhorias significativas no desempenho dos chatbots e assistentes virtuais, tornando as respostas mais contextualizadas e semanticamente ricas (Brown et al., 2020; OpenAI, 2023).

Em contexto organizacional, estas soluções assumem um papel relevante na automação de processos de comunicação, no apoio ao cliente e na gestão do conhecimento interno. Integradas em plataformas de Business Process Management (BPM) e Enterprise Resource Planning (ERP), funcionam como interfaces conversacionais que facilitam o acesso à informação, o encaminhamento de tarefas e o acompanhamento de indicadores operacionais (Jain et al., 2022; Marques & Ferreira, 2023).

No domínio da gestão da qualidade, os assistentes virtuais podem apoiar a análise de relatórios de não conformidades, a gestão de auditorias e o esclarecimento de dúvidas sobre normas e procedimentos, promovendo a uniformização da informação e reduzindo o risco de erro humano (Cheng et al., 2022; Li et al., 2023).

A Tabela 2.5 sintetiza os principais tipos de *chatbots* e assistentes virtuais utilizados no contexto organizacional, destacando as suas características técnicas e as suas aplicações mais comuns.

Tabela 2.5 - Tipos de Chatbots e Assistentes Virtuais nas Organizações.

Tipo de Sistema	Descrição técnica	Aplicações nas organizações
Chatbots baseados em regras	Seguem fluxos de decisão pré-definidos, sem aprendizagem adaptativa.	Atendimento básico, FAQs, suporte interno.
Chatbots com ML / PLN	Utilizam <i>machine learning</i> e compreensão de linguagem natural para gerar respostas dinâmicas.	Apoio ao cliente, helpdesk, gestão documental.
Assistentes virtuais cognitivos	Integram LLMs, aprendizagem contextual e integração com sistemas empresariais.	Apoio à decisão, gestão de qualidade, planeamento e formação.
Chatbots multimodais	Combinam texto, voz e visão computacional.	Interação em ambientes industriais e manutenção assistida.

2.4.7 Desafios, Barreiras e Riscos da Adoção da IA

A adoção da IA nas organizações é amplamente reconhecida como um fator de transformação e de potencial vantagem competitiva. Contudo, a sua implementação enfrenta um conjunto significativo de desafios e riscos de natureza tecnológica, organizacional, ética e estratégica, que condicionam a obtenção de benefícios sustentáveis. Estes obstáculos não se limitam às limitações técnicas dos sistemas inteligentes, abrangendo igualmente fatores humanos, culturais, legais e económicos que influenciam a integração da IA nas práticas de gestão e nos processos produtivos (Dwivedi et al., 2021; European Commission, 2023).

Desafios Tecnológicos e de Implementação

Do ponto de vista tecnológico, um dos principais desafios associados à adoção da IA reside na qualidade, disponibilidade e integridade dos dados. O desempenho dos modelos de *Machine Learning* e *Deep Learning* depende diretamente da quantidade, diversidade e representatividade dos dados utilizados no processo de treino. No entanto, em muitos contextos organizacionais, os dados encontram-se fragmentados, incompletos ou não estruturados, dificultando o desenvolvimento de modelos robustos, fiáveis e imparciais (Marcus & Davis, 2020; NIST, 2023). A integração de soluções de IA com sistemas legados constitui igualmente um entrave relevante, dado que muitas organizações operam com infraestruturas heterogéneas e tecnologicamente desatualizadas, pouco compatíveis com arquiteturas orientadas por dados.

Outro desafio crítico prende-se com a interpretabilidade e a explicabilidade dos modelos de IA. Os algoritmos de aprendizagem profunda, apesar da sua elevada

capacidade preditiva, são frequentemente percebidos como “caixas negras”, dificultando a compreensão dos critérios subjacentes às decisões produzidas. Esta falta de transparência pode comprometer a confiança dos utilizadores e limitar a adoção da IA em setores fortemente regulados, como a saúde, a energia ou o setor financeiro (Gunning & Aha, 2019; Barredo Arrieta & del Ser, 2023).

Acresce ainda que a escalabilidade e a manutenção dos sistemas de IA exigem competências técnicas especializadas e infraestruturas computacionais avançadas. Os custos associados ao desenvolvimento, treino e atualização contínua dos modelos, bem como o consumo energético crescente de modelos de grande escala, colocam desafios económicos e ambientais relevantes (Strubell et al., 2019; Oxford Insights, 2023).

Barreiras Organizacionais e Culturais

No plano organizacional, as principais barreiras à adoção da IA estão relacionadas com a resistência à mudança, a escassez de competências digitais e a ausência de uma cultura organizacional orientada por dados. A literatura evidencia que muitas organizações continuam a encarar a IA como uma ferramenta exclusivamente tecnológica, em vez de a integrarem numa estratégia global de inovação e melhoria contínua (Bughin et al., 2021).

A limitada literacia em IA por parte de gestores e colaboradores compromete a interpretação dos resultados e a utilização eficaz das soluções implementadas. A insuficiência de formação tende a perpetuar decisões baseadas na intuição, em detrimento da evidência analítica, reduzindo o impacto potencial da IA nos processos organizacionais. Paralelamente, a desconfiança em relação a sistemas automatizados, sobretudo em contextos críticos, pode conduzir à rejeição ou subutilização destas tecnologias (Dwivedi et al., 2021).

Outro fator limitativo prende-se com a inexistência de estruturas formais de governação de dados e de políticas internas de ética digital. A ausência de mecanismos claros para assegurar a qualidade, a rastreabilidade e o uso responsável dos dados aumenta o risco de erros, enviesamentos e utilização indevida da informação, dificultando simultaneamente a auditoria e a conformidade regulatória dos sistemas de IA (European Commission, 2021; NIST, 2023).

Riscos Éticos, Legais e Sociais

A aplicação da IA levanta riscos éticos e legais significativos, associados à privacidade, à segurança da informação, à discriminação algorítmica e à atribuição de responsabilidades pelas decisões automatizadas. Diversos estudos demonstram que os modelos de IA podem reproduzir ou amplificar enviesamentos presentes nos dados

de treino, originando decisões injustas ou discriminatórias, com impactos sociais relevantes (Bender et al., 2021; Mitchell et al., 2021).

Em resposta a estes desafios, a Comissão Europeia apresentou em 2021 o AI Act, o primeiro quadro regulatório europeu especificamente dedicado à IA, estabelecendo requisitos de transparência, supervisão humana, gestão de risco e responsabilidade algorítmica. O regulamento propõe uma classificação das aplicações de IA em função do seu nível de risco, impondo obrigações mais exigentes aos sistemas considerados de elevado impacto, incluindo os utilizados em contextos industriais e críticos (European Commission, 2021).

De forma complementar, o AI Risk Management Framework (AI RMF 1.0), publicado pelo NIST em 2023, fornece orientações práticas para a gestão ética e segura de sistemas de IA, enfatizando princípios como transparência, equidade, segurança e explicabilidade. Ambos os enquadramentos convergem na necessidade de promover uma IA fiável, responsável e centrada no ser humano (Trustworthy AI) (NIST, 2023).

Riscos Operacionais e Estratégicos

Ao nível operacional, a dependência excessiva de sistemas de IA pode originar riscos associados ao automation bias e a falhas sistémicas. A automatização de decisões críticas sem supervisão adequada pode amplificar erros de classificação ou previsões incorretas, com consequências financeiras, operacionais e reputacionais significativas (Amodei et al., 2019). Adicionalmente, a crescente interligação entre sistemas inteligentes aumenta a exposição a ameaças cibernéticas, exigindo estratégias robustas de cibersegurança e gestão de vulnerabilidades (Marr, 2022).

Do ponto de vista estratégico, a adoção precipitada de soluções de IA sem alinhamento com os objetivos organizacionais pode conduzir a desperdício de recursos e perda de competitividade. A implementação bem-sucedida da IA requer uma abordagem estruturada que articule estratégia, dados, tecnologia e pessoas, assegurando a criação de valor e a sustentabilidade a longo prazo (Dwivedi et al., 2021).

3 Estudo de Caso

Este capítulo analisa de forma comparativa, a aplicação das tecnologias de Inteligência Artificial na Gestão de Processos e na Gestão da Qualidade, com base em estudos de caso documentados na literatura científica. Na sequência da revisão da literatura apresentada no Capítulo 2, pretende-se compreender de que forma as soluções baseadas em IA são implementadas em contextos industriais reais e quais os seus impactos operacionais e organizacionais.

A abordagem que foi utilizada assenta na análise de estudos de caso múltiplos de natureza secundária, envolvendo aplicações de *Machine Learning*, *Deep Learning*, gémeos digitais, manutenção preditiva e inspeção visual automatizada, enquadradas no contexto da Indústria 4.0 e em transição para princípios associados à Indústria 5.0 (Kim et al., 2023; Giordano et al., 2022; Perno et al., 2023; Hütten et al., 2024).

3.1 Enquadramento e Descrição do Contexto

A integração da IA nas organizações tem vindo a assumir uma relevância crescente, não apenas como suporte tecnológico, mas também como fator estratégico na gestão de processos e da qualidade. Para além da análise conceptual e da revisão da literatura, é essencial observar casos concretos que permitam compreender de que forma a adoção da IA ocorre em contextos reais, quais os desafios enfrentados e que resultados foram alcançados.

A integração da Inteligência Artificial nas organizações tem vindo a assumir um papel crescente não apenas enquanto ferramenta tecnológica, mas também como fator estratégico na melhoria da eficiência operacional, da qualidade dos produtos e da tomada de decisão. Embora a revisão da literatura permita identificar tendências gerais e contributos teóricos relevantes, a análise de casos concretos reportados em contextos industriais reais revela-se essencial para compreender como estas tecnologias são efetivamente aplicadas, quais os constrangimentos enfrentados e que resultados são alcançados.

De acordo com Yin (2018), a utilização de estudos de caso múltiplos constitui uma abordagem metodológica adequada para a análise de fenómenos complexos em contextos reais, permitindo identificar padrões recorrentes e reforçar a robustez analítica das conclusões através da comparação entre diferentes situações. No contexto desta dissertação, esta abordagem é particularmente pertinente, uma vez que a adoção da IA varia significativamente consoante o setor, o tipo de processo e a maturidade digital das organizações.

A seleção dos estudos de caso analisados baseou-se nos seguintes critérios:

- Relevância para a gestão de processos e/ou da qualidade,
- Utilização explícita de tecnologias de Inteligência Artificial,
- Existência de resultados documentados e avaliáveis,
- Diversidade setorial e aplicacional, abrangendo diferentes contextos industriais.

3.2 Apresentação dos Estudos de caso

- **Caso 1- Previsão de níveis de qualidade com aprendizagem semi-supervisionada**

Este estudo de caso analisa a utilização de técnicas de aprendizagem semi-supervisionada e classificação ordinal num processo industrial de fabrico de lâmpadas ultravioleta. Kim et al. (2023) abordam um problema recorrente em sistemas industriais de controlo da qualidade: a limitação de dados rotulados, decorrente dos elevados custos, da complexidade dos procedimentos de inspeção e da necessidade de conhecimento especializado para a rotulagem.

Para ultrapassar esta limitação, os autores propõem um enquadramento baseado em *deep learning* que combina dados rotulados e não rotulados através de um mecanismo de auto-rotulagem orientado pela confiança das previsões. A abordagem incorpora ainda técnicas de classificação ordinal, permitindo respeitar a hierarquia natural entre diferentes níveis de qualidade do produto. Os resultados apresentados demonstram melhorias consistentes no desempenho da previsão da qualidade quando comparados com modelos exclusivamente supervisionados (Kim et al., 2023).

A sua relevância evidencia o contributo da IA para o reforço da gestão da qualidade industrial, nomeadamente através da redução da dependência de inspeções manuais, da melhoria, da consistência, das avaliações e da mitigação dos custos associados à não qualidade.

- **Caso 2 - Gémeo Digital baseado em Machine Learning numa linha de fabrico de catalisadores**

Incide sobre a aplicação de um gémeo digital orientado por machine learning numa linha industrial de fabrico de catalisadores, inserida na indústria de processo. Perno e

Haug (2023) propõem uma abordagem orientada por dados com o objetivo de prever parâmetros críticos do processo produtivo, cuja variabilidade influencia diretamente o desempenho operacional e a qualidade do produto final.

A metodologia apresentada baseia-se na recolha e tratamento de dados reais provenientes do processo industrial, utilizados para treinar modelos preditivos capazes de estimar o comportamento futuro de variáveis críticas. Estes modelos são integrados num ambiente de gémeo digital, permitindo a representação virtual do processo e o apoio à tomada de decisão operacional. Os resultados reportados evidenciam melhorias na capacidade de monitorização do processo e na antecipação de desvios operacionais, contribuindo para a redução da variabilidade e para a melhoria do desempenho global do sistema produtivo (Perno et al., 2023). Demonstra de forma concreta o potencial da IA como instrumento de suporte à gestão de processos industriais complexos, reforçando a ligação entre previsão, controlo do processo e melhoria contínua da qualidade.

- **Caso 3 - Manutenção preditiva orientada por dados na indústria automóvel**

Neste estudo de caso, Giordano et al. (2022) analisam o desenvolvimento de uma solução de manutenção preditiva baseada em dados, aplicada ao setor automóvel. Os autores apresentam o pipeline PREPIPE, concebido para prever o estado de degradação de um sensor de oxigénio utilizado em sistemas de exaustão de motores de combustão interna, com base em dados reais recolhidos em ambiente de ensaio.

A abordagem integra diferentes etapas, incluindo a seleção de sinais relevantes, a extração e seleção de atributos a partir de séries temporais e o treino de modelos de classificação baseados em machine learning. O desempenho do pipeline é comparado com abordagens baseadas em deep learning, concluindo-se que soluções estruturadas e interpretáveis podem alcançar níveis de desempenho semelhantes, mantendo simultaneamente maior transparência e viabilidade de aplicação em contexto industrial (Giordano et al., 2022). O caso mostra a importância na gestão de ativos industriais, demonstrando como a análise orientada por dados pode apoiar decisões de manutenção, reduzir paragens não planeadas e contribuir para a fiabilidade dos processos produtivos.

- **Caso 4 - Detecção explicável de anomalias em sistemas de fabrico**

Choi e Kang (2022) analisam a aplicação de um sistema de deteção de anomalias com capacidade de explicação num processo industrial de natureza química, com o objetivo de antecipar falhas críticas e evitar paragens não planeadas. O estudo compara diferentes técnicas de deteção de anomalias, incluindo métodos estatísticos,

algoritmos de *machine learning* não supervisionado e modelos baseados em redes neurais profundas, recorrendo a dados reais de operação industrial.

Um dos principais contributos deste trabalho reside na integração de mecanismos de explicabilidade, que permitem identificar as variáveis de processo mais relevantes para a deteção de comportamentos anómalos. Esta capacidade de interpretação facilita a compreensão dos resultados por parte dos especialistas de processo e reforça a confiança na utilização de sistemas de apoio à decisão baseados em Inteligência Artificial (Choi & Kang, 2022).

- **Caso 5 - Inspeção visual automática baseada em visão computacional e *deep learning***

Trata-se de um survey que aborda casos de evidências secundárias, assim sendo a aplicação de técnicas de visão computacional suportadas por *deep learning* à inspeção visual automática em contexto industrial, com enfoque no controlo da qualidade. Hütten et al. (2024) realizam uma análise sistemática da literatura recente sobre sistemas de inspeção visual automatizada baseados em redes neurais convolucionais, incidindo sobre aplicações reais nos domínios da produção e da manutenção.

Os autores descrevem soluções que recorrem à análise automática de imagens captadas por câmaras industriais, permitindo a deteção, localização e classificação de defeitos visuais em produtos e componentes. As abordagens analisadas utilizam maioritariamente modelos de *deep learning* treinados com dados reais de produção, aplicados a tarefas como inspeção de superfícies, verificação dimensional e identificação de não conformidades visuais. Os resultados reportados evidenciam melhorias na consistência do controlo da qualidade, na rapidez dos processos de inspeção e na redução de erros associados à avaliação humana (Hütten et al., 2024).

3.3 Metodologia de Análise

A metodologia de análise adotada neste capítulo fundamenta-se nos princípios definidos por Yin (2018), que defendem a utilização de estudos de caso múltiplos como estratégia adequada para a análise de fenómenos complexos, permitindo reforçar a validade externa dos resultados através da replicação teórica.

A investigação baseou-se na análise de artigos científicos com revisão por pares, complementados por literatura académica relevante publicada no período compreendido entre 2018 e 2024. A seleção das fontes teve em consideração critérios de qualidade científica, atualidade e alinhamento com o enquadramento temático da dissertação.

A escolha dos estudos de caso analisados assentou nos seguintes critérios:

1. Pertinência do setor de atividade para os domínios da gestão de processos e da gestão da qualidade;
2. Utilização das tecnologias de IA, nomeadamente ML, DL, aprendizagem semi-supervisionada, visão computacional e abordagens explicáveis;
3. Existência de resultados documentados, que permitam avaliar o contributo das soluções apresentadas e suas dificuldades;
4. Diversidade de contextos aplicacionais, de forma a abranger diferentes cenários industriais.

Cada estudo de caso foi analisado de forma estruturada, segundo um conjunto de dimensões comuns: problema abordado, abordagem tecnológica utilizada, resultados reportados e impactos observados ao nível da gestão de processos e da qualidade. Esta grelha de análise permitiu uma comparação mais sistematizada entre os diferentes casos, servindo de base à discussão desenvolvida nos capítulos subsequentes.

3.4 Análise e Identificação de Problemas e padrões

3.4.1 Análise e identificação de problemas por estudo de caso

Caso 1, Kim et al. (2023), o principal problema identificado prende-se com a escassez de dados rotulados em sistemas de controlo da qualidade industrial. A rotulagem manual dos dados é descrita como um processo dispendioso, demorado e dependente de conhecimento especializado, o que limita a escalabilidade de abordagens supervisionadas tradicionais. Adicionalmente, a variabilidade inerente ao processo produtivo dificulta a generalização dos modelos quando treinados apenas com conjuntos de dados reduzidos. Estes constrangimentos motivam a exploração de abordagens que permitam aproveitar dados não rotulados de forma estruturada.

Caso 2, Perno et al. (2023), o problema central reside na dificuldade de monitorizar e prever parâmetros críticos do processo em ambientes industriais complexos e altamente variáveis. A dependência de medições pontuais e a inexistência de ferramentas eficazes de previsão limitam a capacidade de antecipar desvios operacionais. O estudo mostra ainda desafios relacionados com a integração de modelos preditivos em sistemas industriais existentes, exigindo compatibilidade com infraestruturas tecnológicas e processos já estabelecidos.

Caso 3, Giordano et al. (2022) identifica como problema fundamental a deteção atempada da degradação de componentes críticos, num contexto em que as

abordagens tradicionais de manutenção são maioritariamente reativas ou baseadas em intervalos fixos. Adicionalmente, os autores assinalam limitações associadas ao uso de modelos de *deep learning*, nomeadamente a reduzida compreensão e as exigências computacionais, que dificultam a sua aplicação em ambientes industriais com restrições técnicas e operacionais.

Caso 4, Choi e Kang (2022), o problema central está relacionado com a falta de transparência dos sistemas de deteção de anomalias, especialmente quando baseados em modelos complexos. A dificuldade em compreender as razões subjacentes às decisões dos algoritmos compromete a confiança dos especialistas de processo e limita a utilização prática destes sistemas. Apresenta ainda a necessidade de identificar quais as variáveis de processo que mais contribuem para a ocorrência de comportamentos anómalos.

Caso 5, Hütten et al. (2024) demonstra diversos problemas associados à inspeção visual automatizada, e inspeção manual é propensa a erro e dispendiosa; predominância do supervisionado e dimensões medianas de *dataset* sugerem desafios para treinar modelos “de raiz” e motivam considerar paradigmas alternativos (ex.: auto-supervisionado), além de diferentes exigências de recursos computacionais.

Tabela 3.1 - Análise e identificação de problemas por estudo de caso

Estudo de caso	Contexto	Problema principal identificado	Limitações / desafios evidenciados
Caso 1	Fabrico de lâmpadas uv	Escassez de dados rotulados para controlo da qualidade	- Necessidade de explorar dados não rotulados com controlo de confiança; - Natureza ordinal dos níveis de qualidade
Caso 2	Indústria de processo (catalisadores)	Dificuldade em monitorizar e prever parâmetros críticos do processo, (também via DT-ML)	- Integração de modelos preditivos em sistemas industriais existentes; - Variabilidade do processo
Caso 3	Indústria automóvel	Deteção tardia da degradação de componentes críticos	Limitações das abordagens reativas; reduzida compreensão de modelos complexos
Caso 4	Sistema fabril (Processo industrial de natureza química)	Deteção precoce de sinais de shutdown e explicação das anomalias	- Défice de explicabilidade em abordagens comuns; - Necessidade de interpretação para decisão
Caso 5	Contextos industriais diversos	Limitações da inspeção manual e inconsistência das avaliações	- Dependência de grandes volumes de dados rotulados; - Variabilidade das condições de aquisição de imagem

3.4.2 Padrões transversais identificados

A análise comparativa dos estudos de caso permite identificar um conjunto de padrões recorrentes na aplicação da Inteligência Artificial à gestão de processos e da qualidade em contexto industrial.

Um primeiro padrão relaciona-se com a centralidade dos dados, sendo a sua qualidade, disponibilidade e estruturação determinantes para o desempenho das soluções baseadas em IA. A escassez de dados rotulados surge de forma consistente como um fator limitativo, incentivando a exploração de abordagens alternativas, como a aprendizagem semi-supervisionada e técnicas orientadas por conhecimento de domínio.

Outro padrão transversal prende-se com a necessidade de clareza e confiança nos modelos. Independentemente da aplicação específica, os estudos evidenciam que a aceitação organizacional das soluções de IA depende fortemente da capacidade de explicar os resultados e de apoiar a tomada de decisão de forma transparente, particularmente em ambientes industriais críticos.

A integração das soluções de IA nos sistemas e processos existentes constitui igualmente um padrão recorrente. Os casos analisados demonstram que o impacto das tecnologias inteligentes não depende apenas do desempenho algorítmico, mas também da sua articulação com infraestruturas industriais, fluxos de informação e práticas operacionais consolidadas.

Por fim, emerge como padrão a orientação preditiva das aplicações analisadas. Seja no controlo da qualidade, na monitorização de parâmetros críticos, na manutenção preditiva ou na inspeção visual, a Inteligência Artificial é utilizada predominantemente como ferramenta de antecipação de desvios, falhas ou não conformidades, contribuindo para uma gestão mais proativa dos processos industriais.

Em conjunto, estes padrões evidenciam que, apesar das diferenças entre os contextos analisados, a aplicação da Inteligência Artificial na indústria enfrenta desafios semelhantes e segue linhas de desenvolvimento convergentes. A identificação destes problemas e regularidades constitui a base para a discussão dos constrangimentos à aplicação da IA e para a definição das propostas apresentadas nos capítulos seguintes.

Tabela 3.2 - Padrões transversais identificados na aplicação da IA

Dimensão analisada	Padrão identificado	Evidência nos estudos analisados	Implicações para a gestão
Dados	Centralidade da qualidade, volume e rotulagem dos dados	Escassez de dados rotulados; necessidade de dados fiáveis e representativos	Necessidade de estratégias de gestão e governação de dados
Interpretabilidade	Importância da explicação dos modelos	Preferência por modelos interpretáveis ou com mecanismos de explicação	Reforço da confiança organizacional e apoio à decisão
Integração tecnológica	Dependência da articulação com sistemas existentes	Dificuldades de integração em infraestruturas industriais consolidadas	Necessidade de alinhamento entre IA, processos e sistemas
Orientação preditiva	Foco na antecipação de falhas e desvios	Aplicações em qualidade, manutenção e monitorização de processos	Transição de abordagens reativas para proativas
Competências humanas	Necessidade de envolvimento de especialistas de processo	Dependência de conhecimento de domínio para validação e interpretação	Importância da capacitação e colaboração homem-máquina

3.5 Principais Constrangimentos da Aplicação da IA

Com base nos estudos analisados, mostra que a utilização de Inteligência Artificial em contexto industrial é condicionada, sobretudo, por limitações relacionadas com dados, infraestrutura técnica, explicabilidade e integração organizacional.

Em primeiro lugar, destacam-se os constrangimentos associados aos dados, em particular a rotulagem. No caso da previsão de níveis de qualidade, é sublinhado que a produção de rótulos é onerosa em termos de tempo e custo, o que justifica a exploração de estratégias semi-supervisionadas que combinem dados rotulados e não rotulados. (Kim et al., 2023) Na inspeção visual automatizada, a revisão evidencia a forte dependência de aprendizagem supervisionada e a limitação frequente de conjuntos de dados em aplicações reais, o que condiciona o treino e a generalização dos modelos. No domínio da manutenção/anomalias, é também salientado que eventos de falha são raros e que abordagens supervisionadas requerem exemplos suficientes de estados normais e anómalos, o que nem sempre está disponível (Choi & Kang, 2022).

Em segundo lugar, surgem limitações de infraestrutura e recursos computacionais. No caso automóvel, discute-se que abordagens de DL podem implicar maior capacidade de processamento a bordo ou aumento do volume de sinais a transmitir, o que afeta a viabilidade prática em ambientes com restrições de computação e comunicação.

Um terceiro constrangimento relevante prende-se com a explicabilidade e confiança. Na deteção de anomalias, é enfatizado que muitos métodos identificam desvios, mas não esclarecem “porquê”, motivo pelo qual se recorre a técnicas de interpretação (SHAP) para apoiar decisões técnicas. De forma consistente, o estudo automóvel valoriza pipelines que preservem interpretabilidade para especialistas.

E para terminar, a integração em sistemas e rotinas existentes e a dependência de conhecimento especializado constituem barreiras recorrentes. No caso das anomalias, é referido que abordagens baseadas em regras e conhecimento de domínio são morosas e difíceis de manter, o que dificulta a escalabilidade. No caso do gêmeo digital com ML, os autores assinalam desafios de implementação e a ainda limitada maturidade/literatura aplicada na indústria de processo, reforçando a necessidade de enquadramentos e métodos orientadores (Perno et al., 2023).

4 Propostas de Aplicação da IA

Este capítulo apresenta propostas de aplicação de tecnologias de Inteligência Artificial na gestão de processos e na gestão da qualidade, fundamentadas na revisão da literatura e na análise dos estudos apresentados nos capítulos anteriores. As soluções propostas visam apoiar a melhoria do desempenho operacional, a monitorização de processos e a redução da variabilidade, tendo em conta as limitações técnicas e organizacionais identificadas.

4.1 Ferramentas e Modelos para Otimização de Processos

A otimização de processos industriais é uma das áreas onde a Inteligência Artificial que pode apresentar grande potencial, sobretudo em contextos produtivos complexos e orientados por dados. Conforme discutido na revisão de literatura, as tecnologias de IA permitem reforçar a monitorização e a previsão do comportamento dos processos, ultrapassando limitações dos métodos tradicionais de controlo. A análise dos estudos apresentados no Capítulo 3 confirma a aplicabilidade destas abordagens em ambientes industriais reais.

Entre as ferramentas mais relevantes destacam-se os modelos preditivos baseados em ML, utilizados para estimar parâmetros críticos de processo e apoiar a antecipação de desvios operacionais. A sua integração em gémeos digitais possibilita a criação de representações virtuais dos sistemas produtivos, facilitando a análise de cenários e o apoio à tomada de decisão, particularmente em indústrias de processo (Perno et al., 2023).

A literatura mostra ainda o contributo de abordagens orientadas por dados não rotulados, como a aprendizagem semi-supervisionada, que permitem explorar grandes volumes de informação disponíveis nos sistemas industriais e reduzir a dependência de rotulagem manual, frequentemente onerosa (Kim et al., 2023). Contudo, a eficácia destas soluções depende da sua integração com os sistemas de informação existentes e da existência de pipelines robustos de engenharia de dados, condição

essencial para assegurar a fiabilidade das previsões e a utilidade prática das ferramentas de IA (Giordano et al., 2022).

4.2 Sistemas de Controlo de Qualidade Automatizado

Os sistemas de controlo de qualidade automatizado constituem uma das aplicações mais consolidadas de técnicas de Inteligência Artificial em ambiente industrial, em particular através de inspeção automática suportada por visão computacional e métodos de reconhecimento de padrões (Frese, 2015; Robinson & Miller, 2019). Conforme discutido no Capítulo 2, a integração de técnicas de ML e DL nos sistemas de controlo da qualidade permite ultrapassar limitações associadas à inspeção manual, nomeadamente a subjetividade, a variabilidade dos resultados e os custos operacionais.

Uma das vertentes mais relevantes do controlo de qualidade automatizado prende-se com a previsão e classificação de níveis de qualidade ao longo do processo produtivo. O estudo de Kim et al. (2023) demonstra que a utilização de aprendizagem semi-supervisionada combinada com classificação ordinal permite lidar com a escassez de dados rotulados, problema recorrente em ambientes industriais. Esta abordagem possibilita a exploração de dados não rotulados e respeita a hierarquia natural entre diferentes níveis de qualidade, contribuindo para avaliações mais consistentes e para o apoio à tomada de decisão em tempo útil.

Paralelamente, a inspeção visual automatizada baseada em visão computacional e deep learning assume um papel central nos sistemas de controlo da qualidade. A revisão sistemática realizada por Hütten et al. (2024) indica que redes neuronais convolucionais são amplamente utilizadas para tarefas de deteção, localização e classificação de defeitos visuais em produtos e componentes. Estas soluções permitem aumentar a rapidez da inspeção e reduzir erros associados à avaliação humana, sendo particularmente adequadas a processos onde a inspeção manual é dispendiosa ou suscetível a inconsistências.

Contudo, a literatura sublinha que a eficácia dos sistemas de controlo de qualidade automatizado depende de fatores críticos, como a disponibilidade de dados representativos, a robustez dos modelos face a variações do processo e a integração com os sistemas produtivos existentes. Adicionalmente, a necessidade de adaptação contínua dos modelos a novos produtos ou condições operacionais constitui um desafio relevante, exigindo estratégias de atualização e validação permanentes (Hütten et al., 2024).

4.3 Manutenção Preditiva e Gestão de Ativos

Sendo a manutenção preditiva uma das áreas em que a Inteligência Artificial assume maior relevância na gestão de ativos industriais, ao permitir a monitorização contínua do estado dos equipamentos e a antecipação de falhas (Lee, Bagheri & Kao 2015). Conforme discutido no Capítulo 2, a utilização de técnicas de ML, alinhado também a visão computacional, possibilitam uma abordagem orientada pela condição real dos ativos, reduzindo a dependência de intervenções reativas ou calendarizadas.

Os casos analisados demonstram que a manutenção preditiva baseada em dados recorre à análise de séries temporais provenientes de sensores industriais. O estudo de Giordano et al. (2022) mostra que pipelines estruturados de ML, integrando seleção de sinais e engenharia de atributos, permitem estimar o estado de degradação de componentes críticos, preservando um nível adequado de interpretabilidade para apoio às decisões de manutenção.

Adicionalmente, a literatura destaca a importância da detecção antecipada de anomalias como suporte à gestão de ativos. O trabalho de Choi et al. (2022) mostra que a incorporação de mecanismos de explicabilidade nos modelos de detecção de anomalias facilita a compreensão dos desvios operacionais e apoia intervenções técnicas mais informadas.

No contexto da gestão de ativos, a aplicação da IA contribui para uma planificação mais eficaz das atividades de manutenção e para uma utilização mais eficiente dos recursos disponíveis. Contudo, a sua eficácia depende da qualidade dos dados, da integração com os sistemas de gestão de manutenção e da capacidade das organizações em interpretar a informação gerada pelos modelos (Giordano et al., 2022; Choi et al., 2022).

4.4 Estratégias, Formação e Mudança Cultural

A aplicação eficaz de soluções de Inteligência Artificial em contexto industrial exige mais do que capacidade tecnológica, dependendo igualmente de orientações estratégicas claras, desenvolvimento de competências e adaptação cultural nas organizações. Conforme discutido anteriormente, o valor da IA resulta da sua integração com os processos existentes e da sua utilização como suporte à decisão na gestão de processos e da qualidade (Davenport & Harris, 2017).

Do ponto de vista estratégico, a literatura enfatiza a importância de alinhar as aplicações de IA com objetivos organizacionais bem definidos, assegurando a sua integração nos sistemas e práticas operacionais. Este alinhamento contribui para evitar iniciativas isoladas e reforça a coerência da transformação digital em ambiente industrial (Lee, Bagheri & Kao, 2015).

A formação constitui um fator determinante para a utilização eficaz destas tecnologias. A capacitação das equipas, tanto ao nível técnico como ao nível da interpretação dos resultados produzidos pelos modelos, é essencial para promover uma utilização informada e consistente dos sistemas de apoio à decisão baseados em IA (Davenport & Harris, 2017).

A mudança cultural representa igualmente um desafio relevante, uma vez que a transição para abordagens orientadas por dados implica a revisão de práticas tradicionais e a construção de confiança nos sistemas automatizados. A promoção da transparência, da explicabilidade e do envolvimento dos utilizadores finais surge como condição fundamental para a aceitação das soluções implementadas (European Commission, 2023; NIST, 2023). Em suma, a implementação sustentável da Inteligência Artificial na indústria depende do alinhamento estratégico, do investimento contínuo em formação e da promoção de uma cultura organizacional favorável à utilização responsável e eficaz da tecnologia.

5 Análise e Discussão do estudo

Este capítulo apresenta a análise e discussão dos resultados dos estudos de caso, articulando-os com o enquadramento teórico e as propostas desenvolvidas nos capítulos anteriores. A discussão centra-se na identificação de padrões, benefícios, limitações e fatores críticos associados à aplicação da Inteligência Artificial na gestão de processos e da qualidade no setor industrial. Através da comparação entre a evidência empírica e a literatura, o capítulo permite avaliar os impactos operacionais, estratégicos e organizacionais das soluções analisadas, contribuindo para a consolidação das conclusões da dissertação e para a identificação de oportunidades de investigação futura.

5.1 Avaliação dos Resultados

A avaliação dos resultados baseia-se na evidência reportada nos estudos de caso analisados, considerando os objetivos definidos para a gestão de processos e da qualidade e os critérios metodológicos estabelecidos no Capítulo 3. Dado o caráter essencialmente bibliográfico da dissertação, esta avaliação vai assentar na interpretação crítica dos resultados documentados na literatura.

Para o controlo e previsão da qualidade, o estudo de Kim et al. (2023) demonstra que abordagens de aprendizagem semi-supervisionada, combinadas com classificação ordinal, apresentam melhorias consistentes face a modelos exclusivamente supervisionados, particularmente em cenários caracterizados por escassez de dados rotulados. Os resultados indicam maior robustez das previsões e melhor adequação à hierarquia dos níveis de qualidade, demonstrando o potencial destas técnicas para apoiar decisões de controlo da qualidade em ambiente industrial.

Relativamente à gestão e otimização de processos, o caso do gémeo digital suportado por ML analisado por Perno et al. (2023) apresenta ganhos na capacidade de previsão de parâmetros críticos de processo e no suporte à tomada de decisão operacional. Os autores reportam melhorias na precisão das previsões quando comparadas com

modelos anteriormente utilizados, sublinhando o contributo dos gémeos digitais como instrumentos de monitorização avançada em sistemas produtivos complexos. Para a manutenção preditiva e gestão de ativos, os resultados apresentados por Giordano et al. (2022) indicam que pipelines estruturados de ML permitem estimar o estado de degradação de componentes críticos com desempenho comparável a abordagens de DL, preservando simultaneamente maior interpretabilidade. De forma complementar, o estudo de Choi et al. (2022) diz que a integração de mecanismos de explicabilidade na deteção de anomalias contribui para uma melhor compreensão dos desvios operacionais e reforça a utilidade prática dos sistemas de apoio à decisão.

No que tange da inspeção visual automatizada, a revisão sistemática conduzida por Hütten et al. (2024) reúne evidência de múltiplos estudos que reportam melhorias na consistência e eficiência do controlo da qualidade através da utilização de modelos de DL, particularmente redes neuronais convolucionais. No entanto, os autores salientam que os resultados dependem fortemente da disponibilidade de dados representativos e da adaptação dos modelos às condições específicas de cada contexto produtivo.

Em termos globais, a avaliação dos resultados indica que as tecnologias de IA analisadas apresentam impactos positivos na gestão de processos e da qualidade, sobretudo ao nível da previsão, monitorização e apoio à decisão. Todavia, a literatura também exhibe limitações recorrentes, relacionadas com dados, integração tecnológica, que condicionam a generalização e a transferência direta dos resultados para nos contextos industriais.

5.2 Análise e Interpretação

A análise comparativa dos estudos de caso permite interpretar de forma integrada o contributo da Inteligência Artificial para a gestão de processos e da qualidade no setor industrial. Os resultados indicam que a previsão e monitorização orientadas por dados constituem um elemento comum às diferentes aplicações analisadas, permitindo apoiar a tomada de decisão e reduzir a dependência de abordagens reativas.

A interpretação dos casos analisados confirma que a qualidade e disponibilidade dos dados são determinantes para o desempenho das soluções baseadas em IA. A escassez de dados rotulados, a variabilidade dos processos e a heterogeneidade das fontes de informação surgem como limitações recorrentes, condicionando a generalização dos resultados.

Outro aspeto central prende-se com a necessidade de interpretabilidade. Em aplicações industriais, a aceitação das soluções de IA depende não apenas do desempenho preditivo, mas também da capacidade de explicar os resultados e apoiar decisões técnicas de forma transparente.

Portanto, os resultados indicam que os benefícios da Inteligência Artificial estão fortemente dependentes da sua integração nos processos organizacionais existentes, bem como da capacitação das equipas. Em conjunto, a análise confirma o potencial da IA como suporte à gestão industrial, desde que as soluções sejam desenvolvidas e implementadas de forma alinhada com os contextos técnicos e organizacional

Tabela 5.1 - Tabela comparativa do Estudo de Caso

Estudo de caso	Domínio de aplicação	Tipo de tecnologia de IA	Tipo de decisão apoiada	Impacto principal observado	Grau de maturidade da aplicação	Limitações evidenciadas
Kim et al. (2023)	Controlo e previsão da qualidade	Aprendizagem semi-supervisionada e classificação ordinal (DL)	Apoio à classificação de níveis de qualidade	Melhoria consistente do desempenho preditivo em cenários com poucos dados rotulados	Experimental validado em ambiente industrial	Dependência da qualidade dos pseudo-rótulos; necessidade de validação cuidadosa
Perno et al. (2023)	Otimização e controlo de processos	Machine Learning integrado em gémeo digital	Apoio à decisão operacional e monitorização de parâmetros críticos	Maior precisão na previsão de parâmetros críticos face a modelos anteriores	Aplicação piloto industrial	Dependência de dados históricos suficientes; desafios de integração com sistemas existentes
Giordano et al. (2022)	Manutenção preditiva / gestão de ativos	Machine Learning supervisionado (pipeline interpretável)	Apoio à decisão de manutenção baseada na condição	Desempenho comparável a DL com maior interpretabilidade	Validação experimental com dados industriais reais	Compromisso entre desempenho e complexidade do modelo
Choi et al. (2022)	Deteção de anomalias	ML não supervisionado com técnicas de explicabilidade (SHAP)	Apoio à identificação e interpretação de comportamentos anómalos	Melhoria da compreensão dos desvios e suporte à decisão técnica	Aplicação experimental em contexto industrial	Complexidade na interpretação em sistemas muito dinâmicos
Hütten et al. (2024)	Inspeção visual / controlo da qualidade	Deep Learning (CNNs) – evidência agregada	Apoio à inspeção e deteção de defeitos visuais	Evidência recorrente de maior consistência e eficiência da inspeção	Aplicações industriais reportadas na literatura	Forte dependência de dados rotulados e adaptação ao contexto

5.3 Contribuições, Riscos e Limitações na implementação

A análise dos estudos de caso permite identificar um conjunto de contribuições relevantes da aplicação da Inteligência Artificial à gestão de processos e da qualidade no setor industrial. Entre os principais contributos destaca-se a capacidade da IA para reforçar a previsão, a monitorização e o apoio à tomada de decisão, permitindo uma abordagem mais proativa e orientada por dados. As soluções analisadas evidenciam ganhos ao nível da consistência do controlo da qualidade, da antecipação de desvios operacionais e da gestão baseada na condição de ativos críticos, alinhando-se com os objetivos de melhoria contínua e eficiência operacional.

A integração de técnicas de IA e mecanismos de explicabilidade contribuem para uma melhor compreensão dos processos industriais, promovendo a utilização de modelos como instrumentos de suporte à decisão e não apenas como sistemas automatizados de previsão. Este aspeto é particularmente relevante em contextos industriais complexos, onde a transparência e a confiança nos resultados assumem um papel determinante.

Apesar destes contributos, a literatura analisada prova riscos associados à implementação de soluções de IA. Um dos principais riscos prende-se com a dependência excessiva da qualidade e disponibilidade dos dados, podendo conduzir a resultados enviesados ou pouco robustos quando os dados são incompletos, ruidosos ou pouco representativos. Acrescem riscos relacionados com a integração tecnológica, nomeadamente a compatibilidade com sistemas existentes e a necessidade de adaptação contínua dos modelos a alterações nos processos produtivos.

Por outro lado, as limitações identificadas nos estudos de caso reforçam que a aplicação da IA não constitui uma solução universal. As abordagens analisadas apresentam restrições ao nível da generalização dos resultados, da escalabilidade para diferentes contextos industriais e da exigência de competências técnicas especializadas. A necessidade de equilibrar desempenho preditivo e interpretabilidade surge igualmente como uma limitação recorrente, sobretudo em aplicações críticas para a operação.

A implementação de soluções de Inteligência Artificial na gestão de processos e da qualidade oferecem contributos significativos, mas deve ser encarada de forma crítica e contextualizada. Os sucessos destas iniciativas dependem da mitigação dos riscos identificados e do reconhecimento das limitações existentes, reforçando a importância de estratégias de implementação alinhadas com as características técnicas, organizacionais e humanas de cada contexto industrial ou organizacional.

6 Conclusões

6.1 Principais Conclusões

A presente dissertação permitiu analisar, de forma crítica e fundamentada, o contributo da Inteligência Artificial para a gestão de processos e da qualidade em contextos industriais, com base na evidência disponível na literatura científica e na análise comparativa de estudos de caso reais e survey. Os resultados obtidos confirmam que a IA assume um papel relevante como tecnologia de suporte à tomada de decisão, ao controlo e à previsão da qualidade e à monitorização de processos produtivos, particularmente em ambientes caracterizados por elevada complexidade e grande volume de dados. A análise dos estudos de caso evidenciou que as soluções baseadas em *machine learning* e *deep learning* apresentam capacidade para melhorar a deteção de desvios, antecipar problemas de qualidade e apoiar a otimização de processos, desde que sejam sustentadas por dados de qualidade e integradas de forma eficaz nos sistemas produtivos existentes. Verificou-se, contudo, que os benefícios reportados dependem fortemente da maturidade tecnológica das organizações, da adequação das infraestruturas de dados e da disponibilidade de competências técnicas especializadas. De igual modo, a dissertação permitiu identificar um conjunto de riscos e limitações associados à integração da IA na indústria, nomeadamente a reduzida interpretabilidade de alguns modelos, os desafios de escalabilidade, a dependência tecnológica e a necessidade de adaptação organizacional. Estes fatores reforçam a importância de uma abordagem estruturada, gradual e alinhada com os objetivos estratégicos das organizações.

Em conclusão, constata-se que a Inteligência Artificial constitui um instrumento com elevado potencial para a melhoria da gestão de processos e da qualidade, cuja implementação deve ser orientada por uma avaliação crítica dos seus impactos, limitações e condições de aplicação, de forma a assegurar a criação de valor sustentável no contexto industrial.

6.2 Limitações do Estudo

Apesar da abrangência dos casos e da fundamentação teórica, o estudo apresenta algumas limitações nomeadamente:

- O estudo baseia-se numa abordagem predominantemente bibliográfica, não contemplando validação empírica direta em contexto industrial real.
- A heterogeneidade dos estudos de caso analisados, quanto aos setores, objetivos, técnicas de Inteligência Artificial e métodos de validação, limita a comparabilidade direta dos resultados.
- A diversidade metodológica dos trabalhos analisados impede a generalização das conclusões a diferentes contextos organizacionais e produtivos.
- A análise depende da informação reportada pelos autores, existindo limitações ao nível do detalhe dos dados, das métricas utilizadas e dos resultados quantitativos apresentados.
- A ausência, em alguns estudos, de validação em ambiente operacional contínuo restringe a avaliação do impacto real das soluções propostas.
- A rápida evolução das tecnologias de Inteligência Artificial pode comprometer a atualidade de parte dos métodos e abordagens analisados.

6.3 Perspetivas de Investigação Futura

A evolução da IA abre novas linhas de investigação, tanto académicas como aplicadas, que podem aprofundar e complementar este estudo como passo a enumerá-las abaixo:

1. Realização de estudos empíricos em ambiente industrial real, com validação quantitativa e longitudinal dos impactos da Inteligência Artificial no desempenho dos processos e da qualidade.
2. Desenvolvimento de metodologias e métricas normalizadas que permitam comparar de forma consistente diferentes aplicações de IA em contextos industriais.
3. Investigação sobre a integração das soluções de IA com sistemas industriais existentes, nomeadamente sistemas de execução da produção e sistemas de gestão da qualidade.
4. Análise dos impactos organizacionais e das competências necessárias à implementação da IA, incluindo formação, gestão da mudança e adaptação dos recursos humanos.

5. Estudo da aplicação da IA em diferentes setores industriais e em empresas de diversas dimensões, de forma a avaliar a transferibilidade e sustentabilidade das soluções.

.
E para concluir, este trabalho confirma que a Inteligência Artificial se apresenta como um leque de ativos de gestão, com impacto significativo na eficiência, qualidade, inovação das organizações. A introdução bem-sucedida vai exigir não apenas investimento tecnológico, mas sobretudo mudança cultural, formação contínua e governança ética, fatores que se revelam determinantes para transformar a IA de uma promessa tecnológica em vantagem competitiva sustentável.

Referências bibliográficas

- Adamopoulou, E., & Moussiades, L. (2020). Chatbots: History, technology, and applications. *Machine Learning with Applications*, 2, 100006. <https://doi.org/10.1016/j.mlwa.2020.100006>
- Alpaydin, E. (2021). *Introduction to machine learning* (4th ed.). MIT Press.
- Amodei, D., Olah, C., Steinhardt, J., Christiano, P., Schulman, J., & Mané, D. (2016). Concrete problems in AI safety. *arXiv*. Consultado em dezembro de 2025, em <https://arxiv.org/abs/1606.06565>
- Arrieta, A. B., Díaz-Rodríguez, N., del Ser, J., Bennetot, A., Tabik, S., Barbado, A., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Barredo Arrieta, A., & del Ser, J. (2023). *Explainable machine learning in practice*. Springer. <https://doi.org/10.1007/978-3-031-04083-2>
- Bekey, G. A. (2005). *Autonomous robots: From biological inspiration to implementation and control*. MIT Press.
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the ACM Conference on Fairness, Accountability, and Transparency (FAccT)*, 610–623. <https://doi.org/10.1145/3442188.3445922>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bishop, C. M., & Nasrabadi, N. M. (2023). *Pattern recognition and machine learning* (2nd ed.). Springer.
- Bommasani, R., et al. (2021). On the opportunities and risks of foundation models. *arXiv*. Consultado em dezembro de 2025, em <https://crfm.stanford.edu/assets/report.pdf>
- Brown, T. B., et al. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901. Consultado em dezembro de 2025, em <https://arxiv.org/abs/2005.14165>
- Brynjolfsson, E., & McAfee, A. (2017). *Machine, platform, crowd: Harnessing our digital future*. W. W. Norton & Company.

- Bughin, J., Hazan, E., Ramaswamy, S., Chui, M., Allas, T., Dahlström, P., Henke, N., & Trench, M. (2017). Artificial intelligence: The next digital frontier? McKinsey Global Institute. Consultado em dezembro de 2025, em <https://www.mckinsey.com/~media/mckinsey/industries/advanced%20electronics/our%20insights/how%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/mgi-artificial-intelligence-discussion-paper.pdf>
- Cambria, E., Poria, S., Hazarika, D., & Kwok, K. (2022). SenticNet 7: A commonsense-based neurosymbolic AI framework for explainable sentiment analysis. In Proceedings of the 13th Language Resources and Evaluation Conference (LREC) (pp. 3829–3839). Consultado em dezembro de 2025, em <https://aclanthology.org/2022.lrec-1.408/>
- Camarinha-Matos, L. M., & Ferrada, F. (2021). Collaborative intelligent systems in Industry 4.0. *Annual Reviews in Control*, 52, 329–346.
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM Computing Surveys*, 41(3), 1–58. <https://doi.org/10.1145/1541880.1541882>
- Cho, K., et al. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP).
- Choi, H., & Kang, P. (2022). Explainable anomaly detection framework for predictive maintenance in manufacturing systems. *Applied Soft Computing*, 125, 109147. <https://doi.org/10.1016/j.asoc.2022.109147>
- Crosby, P. B. (2002). *Quality is free: The art of making quality certain*. McGraw-Hill.
- Davenport, T. H. (1993). *Process innovation: Reengineering work through information technology*. Harvard Business School Press.
- Davenport, T. H., & Harris, J. G. (2017). *Competing on analytics: The new science of winning*. Harvard Business Review Press.
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- Deming, W. E. (2000). *Out of the crisis*. MIT Press.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. In Proceedings of NAACL-HLT 2019 (pp. 4171–4186). Consultado em dezembro de 2025, em <https://aclanthology.org/N19-1423/>
- Dwivedi, Y. K., Hughes, L., Baabdullah, A. M., Ribeiro-Navarrete, S., Giannakis, M., Buhalis, D., ... & Wright, R. (2021). Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2020.101994>
- Dumas, M., La Rosa, M., Mendling, J., & Reijers, H. A. (2018). *Fundamentals of business process management* (2nd ed.). Springer.
- European Commission. (2021). Proposal for a Regulation ... laying down harmonised rules on artificial intelligence (Artificial Intelligence Act), COM(2021) 206 final. Consultado em dezembro de 2025, em <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:52021PC0206>
- European Commission. (2023). *Industry 5.0: Towards a sustainable, human-centric and resilient European industry*. Publications Office of the European Union. Consultado em dezembro de 2025, em <https://op.europa.eu/en/publication-detail/-/publication/aed3280d-70fe-11eb-9ac9-01aa75ed71a1>

- Frese, C. (2015). *Machine vision: Automated visual inspection*. Springer.
- Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2020). A survey on concept drift adaptation. *ACM Computing Surveys*, 53(4), 1–37.
- Géron, A. (2023). *Hands-on machine learning with Scikit-Learn, Keras & TensorFlow* (3rd ed.). O'Reilly Media.
- Giarratano, J. C., & Riley, G. D. (2005). *Expert systems: Principles and programming* (4th ed.). Thomson Course Technology.
- Giordano, D., Giobergia, F., Pastor, E., La Macchia, A., Cerquitelli, T., Baralis, E., Mellia, M., & Tricarico, D. (2022). Data-driven strategies for predictive maintenance: Lesson learned from an automotive use case. *Computers in Industry*, 134, 103554. <https://doi.org/10.1016/j.compind.2021.103554>
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Goodfellow, I. J., et al. (2014). Generative adversarial nets. In *Advances in Neural Information Processing Systems (NeurIPS)* (Vol. 27, pp. 2672–2680).
- Grieves, M., & Vickers, J. (2017). Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In *Transdisciplinary perspectives on complex systems*. Springer.
- Gunning, D., & Aha, D. W. (2019). DARPA's Explainable Artificial Intelligence (XAI) program. *AI Magazine*, 40(2), 44–58. <https://doi.org/10.1609/aimag.v40i2.2850>
- Hammer, M. (2015). What is business process management? In J. vom Brocke & M. Rosemann (Eds.), *Handbook on business process management 1* (pp. 3–16). Springer.
- Hammer, M., & Champy, J. (1993). *Reengineering the corporation: A manifesto for business revolution*. HarperBusiness.
- Han, J., Kamber, M., & Pei, J. (2011). *Data mining: Concepts and techniques* (3rd ed.). Morgan Kaufmann.
- Haralick, R. M., & Shapiro, L. G. (1992). *Computer and robot vision* (Vols. 1–2). Addison-Wesley.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hoy, M. B. (2018). Alexa, Siri, Cortana, and more: An introduction to voice assistants. *Medical Reference Services Quarterly*, 37(1), 81–88.
- Hütten, N., Gomes, M. A., Hölken, F., Andricevic, K., Meyes, R., & Meisen, T. (2024). Deep learning for automated visual inspection in manufacturing and maintenance. *Applied Systems Innovation*, 7(1), 11. <https://doi.org/10.3390/asi7010011>
- ISO. (2015). *ISO 9001:2015 — Quality management systems — Requirements*. International Organization for Standardization.
- Jain, R., Gupta, A., & Singh, M. (2022). Conversational AI in industry: Frameworks and opportunities. *IEEE Transactions on Industrial Informatics*, 18(9), 6479–6489.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/science.aaa8415>
- Juran, J. M. (2005). *Juran's quality handbook: The complete guide to performance excellence* (6th ed.). McGraw-Hill.

- Juran, J. M., & Godfrey, A. B. (1999). *Juran's quality handbook* (5th ed.). McGraw-Hill.
- Jurafsky, D., & Martin, J. H. (2023). *Speech and language processing* (3rd ed., draft). Stanford University.
- Kagermann, H., Wahlster, W., & Helbig, J. (2013). Recommendations for implementing the strategic initiative Industrie 4.0. acatech. Consultado em dezembro de 2025, em <https://www.acatech.de/>
- Kim, G., Choi, J. G., Ku, M., & Lim, S. (2023). Developing a semi-supervised learning and ordinal classification framework for quality level prediction in manufacturing. *Computers & Industrial Engineering*, 181, 109286. <https://doi.org/10.1016/j.cie.2023.109286>
- Kingma, D. P., & Welling, M. (2019). Auto-encoding variational Bayes: Revisited. *Foundations and Trends in Machine Learning*, 12(3), 307–392.
- Klopfenstein, L. C., et al. (2017). The rise of bots: A survey of conversational interfaces. In *Proceedings of the International Conference on Conversational User Interfaces*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lenke, L. R., McKeen, R. G., & Grush, M. P. (2003). Laboratory evaluation of GeoGauge for compaction control. *Transportation Research Record*, 1849, 20–30. <https://doi.org/10.3141/1849-03>
- Lee, J., Bagheri, B., & Kao, H. A. (2014). A cyber-physical systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, 3, 18–23. <https://doi.org/10.1016/j.mfglet.2014.12.001>
- Li, J., Chen, P., & Zhao, Y. (2023). Leveraging NLP for customer feedback analysis in quality improvement. *Total Quality Management & Business Excellence*, 34(9–10), 1124–1141.
- Marcus, G., & Davis, E. (2020). *Rebooting AI: Building artificial intelligence we can trust*. Pantheon Books.
- Marr, B. (2022). *Artificial intelligence in practice: How 50 successful companies used AI to solve problems*. Wiley.
- Marsland, S. (2020). *Machine learning: An algorithmic perspective* (3rd ed.). CRC Press.
- Marques, P., & Ferreira, M. (2023). The role of conversational AI in process digitalization. *European Journal of Management and Business Economics*, 32(3), 221–238.
- McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. (1956). A proposal for the Dartmouth summer research project on artificial intelligence. Dartmouth College. Consultado em dezembro de 2025, em <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. arXiv.
- Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., ... & Gebru, T. (2021). Model cards for model reporting. *Communications of the ACM*, 64(12), 56–64. <https://doi.org/10.1145/3287560>
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- NIST – National Institute of Standards and Technology. (2023). *Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1)*. Consultado em dezembro de 2025, em <https://nvlpubs.nist.gov/nistpubs/ai/nist.ai.100-1.pdf>
- Oakland, J. S. (2014). *Total quality management and operational excellence: Text with cases* (5th ed.). Routledge.

- OpenAI. (2023). GPT-4 technical report. arXiv. Consultado em dezembro de 2025, em <https://arxiv.org/abs/2303.08774>
- Owens, J. D., Houston, M., Luebke, D., Green, S., Stone, J. E., & Phillips, J. C. (2008). GPU computing. *Proceedings of the IEEE*, 96(5), 879–899. <https://doi.org/10.1109/JPROC.2008.917757>
- Oxford Insights. (2023). Government AI Readiness Index 2023. Consultado em dezembro de 2025, em <https://oxfordinsights.com/wp-content/uploads/2023/12/2023-Government-AI-Readiness-Index-1.pdf>
- Pennington, J., Socher, R., & Manning, C. D. (2014). GloVe: Global vectors for word representation. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (pp. 1532–1543).
- Perno, M., Hvam, L., & Haug, A. (2023). A machine learning digital twin approach for critical process parameter prediction in a catalyst manufacturing line. *Computers in Industry*, 151, 103987. <https://doi.org/10.1016/j.compind.2023.103987>
- Pyzdek, T., & Keller, P. (2014). *The six sigma handbook: A complete guide for Green Belts, Black Belts, and managers at all levels* (4th ed.). McGraw-Hill.
- Pyzdek, T., & Keller, P. (2018). *The six sigma handbook* (5th ed.). McGraw-Hill.
- Raffel, C., Shazeer, N., Roberts, A., et al. (2020). Exploring the limits of transfer learning with a unified text-to-text transformer. *Journal of Machine Learning Research*, 21(140), 1–67.
- Raschka, S., Mirjalili, V., & Hearty, J. (2022). *Python machine learning* (4th ed.). Packt.
- Robinson, S. L., & Miller, R. K. (2019). *Automated inspection and quality assurance*. CRC Press / Routledge.
- Russell, S., & Norvig, P. (2022). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646. <https://doi.org/10.1109/JIOT.2016.2579198>
- Siciliano, B., & Khatib, O. (2023). *Springer handbook of robotics* (2nd ed.). Springer.
- Silver, D., Singh, S., Precup, D., & Sutton, R. S. (2021). Reward is enough. *Artificial Intelligence*, 299, 103535. <https://doi.org/10.1016/j.artint.2021.103535>
- Strubell, A., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in natural language processing. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics* (pp. 3645–3650). <https://doi.org/10.18653/v1/P19-1355>
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.
- Syed, R., et al. (2020). Robotic process automation: Contemporary themes and challenges. *Computers in Industry*, 115, 103162.
- Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2nd ed.). Springer.
- Thrun, S., Burgard, W., & Fox, D. (2022). *Probabilistic robotics*. MIT Press.
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460.
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems (NeurIPS)*. Consultado em dezembro de 2025, em <https://arxiv.org/abs/1706.03762>

Womack, J. P., & Jones, D. T. (2003). *Lean thinking: Banish waste and create wealth in your corporation* (2nd ed.). Free Press.

Yin, R. K. (2018). *Case study research and applications: Design and methods* (6th ed.). Sage Publications.

Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, 13(3), 55–75. <https://doi.org/10.1109/MCI.2018.2840738>