



UNIVERSIDADE DE
COIMBRA

Jorge Diamantino Moreira Barbosa

**MANUTENÇÃO PREDITIVA COM RECURSO A
INTELIGÊNCIA ARTIFICIAL**

**Dissertação de Mestrado Integrado em Engenharia Eletrotécnica e de
Computadores, na área de Especialização em Robótica, Controlo e
Inteligência Artificial, orientada pelo Professor Doutor Paulo Jorge Carvalho
Menezes e apresentada ao Departamento de Engenharia Eletrotécnica e de
Computadores da Faculdade de Ciências e Tecnologia da Universidade de
Coimbra.**

Julho de 2023



UNIVERSIDADE DE COIMBRA

Jorge Diamantino Moreira Barbosa

Manutenção preditiva com recurso a Inteligência Artificial

Dissertação realizada no âmbito do Mestrado Integrado em Engenharia Eletrotécnica e de Computadores, ramo de Robótica, Controlo e Inteligência Artificial, sob a orientação do Sr. Professor Doutor Paulo Jorge Carvalho Menezes, apresentado ao Departamento de Engenharia Eletrotécnica e de Computadores da Faculdade de Ciências e Tecnologias da Universidade de Coimbra

Júri:

Sr. Professor Doutor Sérgio Manuel Ângelo da Cruz (Presidente Júri)
Sr. Professor Doutor Álvaro Filipe Peixoto Cardoso de Oliveira Gomes
Sr. Professor Doutor Paulo Jorge Carvalho Menezes

Coimbra, 2023

Este projeto foi desenvolvido em colaboração com:

Universidade de Coimbra



Departamento de Engenharia Eletrotécnica e de Computadores



Instituto de Sistemas e Robótica



Lider Global em Soluções de Energias Sustentáveis



Agradecimentos

Gostaria de expressar o meu profundo agradecimento a todas as pessoas que contribuíram para o sucesso desta dissertação. Sem o apoio e incentivo de cada um de vocês, não teria sido possível alcançar este marco importante na minha jornada acadêmica.

Em primeiro lugar, gostaria de expressar o meu agradecimento ao meu orientador, Paulo Menezes, que me guiou ao longo deste processo. A sua sabedoria, orientação e constante motivação foram fundamentais para o desenvolvimento deste trabalho. Agradeço a sua dedicação em ajudar-me a expandir os meus conhecimentos, habilidades acadêmicas e valores pessoais.

A minha namorada, Joana, que tem sido um pilar de apoio incondicional, merece uma menção especial. O seu amor, compreensão e paciência foram fundamentais para a minha motivação e perseverança durante todo o período de elaboração desta dissertação. A sua presença constante ao meu lado e as suas palavras de coragem foram um verdadeiro impulso para superar os desafios.

Também desejo expressar o meu obrigado ao Paulo Moreira, onde tive a oportunidade de trabalhar durante este período. A sua experiência e orientação foram inestimáveis para a minha compreensão das aplicações neste tipo de trabalho.

Além disso, gostaria de destacar que conciliar o trabalho e a elaboração desta dissertação não foi uma tarefa fácil. No entanto, ao longo de todo este processo o meu manager, Miguel, desempenhou um papel crucial na gestão desta montanha russa. A sua compreensão e apoio em relação aos prazos e exigências académicas foram fundamentais para que eu pudesse conciliar as responsabilidades profissionais com o desenvolvimento desta dissertação.

Não posso deixar de mencionar os meus pais, cujo apoio e investimento na minha educação foram fundamentais. Eles acreditaram sempre em mim e proporcionaram-me as ferramentas necessárias para alcançar os meus objetivos. Sou eternamente grato pelo amor incondicional, incentivo constante e sacrifícios para me proporcionarem o melhor.

Por fim, dedico esta dissertação ao Sr. Tiago, cuja influência na minha vida foi e continuará a ser inspiradora. Espero que este trabalho possa refletir não apenas os meus esforços, mas também honrar a sua influência positiva na minha trajetória académica e pessoal.

A todos vocês, expresse o meu sincero agradecimento. O vosso apoio, encorajamento e contribuições foram imprescindíveis para o sucesso deste projeto. Sou eternamente grato por ter pessoas tão incríveis na minha vida e por fazerem parte desta conquista.

Abstract

The present dissertation was developed in the context of the Integrated Master's Degree in Electrical And Computers Engineering, specialization in Control, Robotics and Artificial intelligence, in the Faculty of Science and Technology of the Coimbra University. The growing competitiveness of the market, coupled with the increase in automation driven by the advent of the Industry, highlights the importance of maintenance within organizations. At the same time, the amount of data capable of being extracted from industrial systems has increased exponentially due to the proliferation of sensors, transmission devices and data storage via Internet of Things. These data, when processed and analyzed, can provide valuable information and knowledge about the equipment, allowing a move towards predictive maintenance. Maintenance is fundamental to a company's competitiveness, since actions taken at this level have a direct impact on aspects such as cost and quality of products. Hence, equipment failures need to be identified and resolved. Artificial Intelligence tools, in particular Machine Learning, exhibit enormous potential in the analysis of large amounts of data, now readily available, thus aiming to improve the availability of systems, reducing maintenance costs, increasing operational performance and support in decision making. In this dissertation, Artificial Intelligence tools, more specifically Machine Learning, are applied to a set of data made available from Vestas and the specifics of this implementation are analyzed as well as the definition of methodologies, in order to provide information and tools to the maintenance area.

Resumo

A presente dissertação foi desenvolvida no âmbito do Mestrado em Engenharia Eletrotécnica e de Computadores, ramo de Controlo, Robótica e Inteligência Artificial, da Faculdade de Ciências e Tecnologias da Universidade de Coimbra. A crescente competitividade do mercado aliada ao aumento da automatização impulsionado pelo advento da Indústria põe em destaque a importância da manutenção no seio das organizações. Simultaneamente, a quantidade de dados capazes de ser extraídos de sistemas industriais aumentou de forma exponencial devido à proliferação de sensores, dispositivos de transmissão e armazenamento de dados via Internet of Things. Estes dados, quando processados e analisados, podem fornecer informações e conhecimentos valiosos acerca dos equipamentos, permitindo uma movimentação no sentido de uma manutenção preditiva. A manutenção é fundamental para a competitividade de uma empresa, uma vez que as ações realizadas a esse nível têm impacto direto em aspetos como o custo e qualidade dos produtos. Assim, falhas nos equipamentos necessitam de ser identificadas e resolvidas. As ferramentas de Inteligência Artificial, em particular o Machine Learning, exibem um enorme potencial na análise de grandes quantidades de dados, agora prontamente disponíveis, permitindo assim ambicionar uma melhoria na disponibilidade dos sistemas, reduzindo os custos de manutenção, aumentando o desempenho operacional e ainda a capacidade de apoio na tomada de decisão. Na presente dissertação, aplicam-se ferramentas de Inteligência Artificial, mais especificamente de Machine Learning, a um conjunto de dados disponibilizados pela Vestas e procura-se analisar as especificidades desta implementação assim como a definição de metodologias, com vista a permitir fornecer informações e ferramentas à área da manutenção.

Lista de Figuras

2.1	Distribuição de Energia Eólica.	9
2.2	Turbina de eixo vertical.	11
2.3	Turbina de eixo horizontal.	12
2.4	Estrutura de uma turbina eólica de eixo horizontal.	13
2.5	Curva-PF.	18
2.6	Anomalias na curva PF.	19
2.7	Relação entre a Curva PF e a Curva de custos.	20
2.8	Curva da banheira.	22
2.9	Gestão da manutenção.	23
2.10	Processo formação de vernizes.	29
2.11	Exemplo de um Gráfico FTIR.	30
2.12	Diferenças entre IA, ML e DL.	31
2.13	Exemplos de supervised learning.	33
2.14	Diferença entre Clustering e Association Rule Mining.	34
2.15	Anomaly Detection.	34
2.16	Semi-Supervised Learning	35
2.17	Batch e Online Learning	36
2.18	Instance based learning	37
2.19	Model based learning	37
2.20	Rede neuronal com 4 camadas.	38
2.21	Proposta de <i>workflow</i> de um projeto de <i>Machine Learning</i>	39
2.22	Exemplo de <i>feature engineering</i>	41
2.23	Repartição ideal de um conjunto de dados	42
2.24	Diferença de <i>underfitting</i> e <i>overfitting</i>	43
2.25	Diferença de <i>bias</i> e <i>variance</i>	45
2.26	Matriz de Confusão para um problema de classificação binária	46
3.1	Arquitetura do sistema.	49
3.2	Exemplo do ficheiro dos dados de treino.	50
3.3	Gráfico FTIR.	52
3.4	Implementação das camadas do teste 11.	55
3.5	Estrutura da rede neuronal, resultado da implementação da figura 3.4.	55

3.6	Matriz de confusão do modelo final com os testes de verificação.	59
3.7	Relação do modelo com a necessidade de manutenção.	60

Lista de Tabelas

3.1	Descrição de cada característica.	50
3.2	Distribuição temporal das amostras.	52
3.3	Distribuição das amostras.	52
3.4	Determinação do numero de camadas intermédias.	54
3.5	Determinação do melhor otimizador.	56
3.6	Determinação da melhor taxa de aprendizagem.	56
3.7	Determinação do numero de épocas.	58

Lista de Acrónimos e Símbolos

MP	Manutenção Preditiva
ML	Machine Learning
CLP	Controlador Lógico Programável
MTTR	Mean Time to Repair
TTR	Time to Repair
MTBF	Mean Time Between Failures
TBF	Time Between Failures
λ	Taxa de falhas
ICP-MS	Inductively coupled plasma-mass spectrometry

Conteúdo

Lista de Figuras	vi
Lista de Tabelas	viii
1 Introdução	1
1.1 Enquadramento	1
1.2 Trabalhos recentes	2
1.3 Objetivos	7
1.4 Estrutura da Dissertação	7
2 Fundamentos	8
2.1 Introdução	8
2.2 Energias Renováveis	8
2.2.1 Energia Eólica	9
2.2.2 Tipos de Turbinas Eólicas	10
2.3 Manutenção Industrial	14
2.3.1 Manutenção Corretiva	16
2.3.2 Manutenção Preventiva	16
2.3.3 Manutenção Preditiva	17
2.3.4 Falha, Avaria e Modo de Falha	17
2.3.5 Curva PF	18
2.3.6 Manutenibilidade	20
2.3.7 Fiabilidade e Disponibilidade	21
2.3.8 Gestão da Manutenção	23
2.4 Lubrificantes e Técnicas de Análise de óleo lubrificante	24
2.4.1 Lubrificantes	24
2.4.2 Análise de óleo lubrificante	26
2.4.3 Tipos de análises a óleos lubrificantes	26
2.5 Inteligência Artificial	30
2.5.1 Introdução	30
2.5.2 Conceitos de <i>Machine Learning</i>	31
2.6 Industria e Inteligência Artificial	47

3	Aplicação de modelos de Machine learning e Resultados	49
3.1	Origem dos dados	50
3.2	Divisão dos dados	51
3.3	Análise dos dados de treino	52
3.4	Detalhes da implementação	52
3.5	Escolha e treino do modelo	53
3.6	Avaliação do modelo	58
3.7	Conclusões	59
4	Conclusões e Trabalho Futuro	61
4.1	Conclusões	61
4.2	Trabalhos Futuros	63
	Bibliografia	64

Capítulo 1

Introdução

1.1 Enquadramento

Na economia globalizada atual, o ambiente competitivo, caracterizado pelo aparecimento crescente e cada vez mais rápido de novas técnicas e tecnologias nos processos e produtos, leva a que a sobrevivência das organizações dependa da sua capacidade de inovar, da atualização constante e da procura incessante pela otimização de soluções. Estas mudanças estão relacionadas principalmente com o aumento da variedade de aspetos físicos (equipamentos, sistemas e estruturas) e com a crescente preocupação do seu impacto no ambiente, segurança, mais valias económicas e qualidade dos produtos. A melhoria contínua nos processos e o espírito de inovação são realidades que podem ser observadas de diversas formas nas áreas que constituem uma empresa. É fundamental procurar uma diferenciação que possibilite uma melhoria na posição estratégica no mercado atual. Assim sendo, um dos setores que pode representar um custo significativo, e que tem despertado as empresas para a implementação de um desenvolvimento contínuo, é o setor de manutenção [1].

A manutenção constitui um fator relevante para a competitividade de uma empresa, uma vez que as ações realizadas a esse nível têm impacto direto em aspetos como o custo, prazo e qualidade dos produtos produzidos ou serviços prestados. A manutenção é um suporte à área operacional de uma empresa, não podendo ser dissociada desta, dada a implicação que tem ao nível da eficiência dos ativos produtivos. Estas duas áreas, operação e manutenção, têm obrigatoriamente de funcionar em paralelo de modo a garantir a disponibilidade dos meios humanos e materiais aos problemas operacionais, permitindo assim assegurar o cumprimento dos objetivos com a maximização dos recursos disponíveis. Desta forma, passa a ser importante, não só, atingir os objetivos propostos, mas atingi-los com o mínimo consumo ou utilização de recursos [2].

É neste contexto de transformação constante, de rápidas mudanças tecnológicas, que surge uma revolução baseada na incorporação de tecnologias de informação e comunicação em processos industriais tradicionais, criando uma conexão entre os diversos sistemas, conhecida como Indústria 4.0 [1]. A Indústria 4.0 é um conceito que surge em novembro de 2011, relativamente a uma

estratégia de desenvolvimento tecnológico. É caracterizada pela fusão conceptual de tecnologias que encurtam a fronteira entre os sistemas físico, digital e o ser humano, através de um conjunto de avanços e desenvolvimentos tecnológicos disruptivos, que afetam a indústria a nível global, tais como a Internet of Things (IoT), Cyber-Physical Systems (CPS), Virtual/Augmented Reality (VR/AR), Big Data e Cloud Computing [2].

A Indústria 4.0 implementa as ferramentas fornecidas pelos avanços nas tecnologias de informação e comunicação de modo a aumentar os níveis de automação e digitalização nos processos industriais e de produção. O objetivo é gerir todo o processo da cadeia de valor, melhorando a eficiência da produção e criação de produtos e serviços de qualidade superior. Um dos pontos chave desta revolução são os dados, que agora são lidos, processados, armazenados, analisados e partilhados muito mais facilmente entre máquinas e o ser humano [3].

A IoT é definida como um ecossistema no qual os objetos e equipamentos nele inseridos estão equipados com sensores e outros dispositivos digitais, sendo assim capazes de reunir e trocar informações uns com os outros, num sistema interligado em rede. Esta tecnologia permitirá avanços significativos na execução e gestão de tarefas em tempo real [1].

Nos últimos anos, uma queda no custo e um aumento da fiabilidade de sensores, dispositivos de transmissão e armazenamento de dados promoveram o aparecimento de sistemas de monitorização de condições. Simultaneamente, a IoT permite uma transmissão em tempo real destas informações acerca das condições dos sistemas capturadas por diversos dispositivos de monitorização. Este desenvolvimento oferece uma excelente oportunidade para usar os dados de monitorização de condições de forma inteligente dentro dos regimes de manutenção preditiva, aliando a capacidade de recolha de dados a uma análise efetiva e integrada dos mesmos. Neste sentido, o potencial das ferramentas de Inteligência Artificial, mais concretamente o Machine Learning, prevê com muita confiança uma melhoria na disponibilidade dos sistemas, reduzindo os custos de manutenção, aumentando o desempenho operacional e ainda a capacidade de apoio na tomada de decisão em relação ao ponto ideal no tempo e a ação ideal para a realização da intervenção de manutenção [4].

A Inteligência Artificial em algumas das suas vertentes, como o Machine Learning, está frequentemente associada à análise de dados. Machine Learning pode ser definido como o campo de estudo que dá ao computador a habilidade de aprender sem ser explicitamente programado. Pode dizer-se que os algoritmos de Machine Learning usam métodos computacionais para aprender informação diretamente dos dados sem recurso a equações pré-definidas como modelo [5].

1.2 Trabalhos recentes

Neste capítulo, serão explorados os trabalhos existentes de manutenção preditiva e inteligência artificial, que têm contribuído para o avanço desta área e foram publicados nos últimos 5 anos. Serão discutidas as teorias fundamentais, modelos e abordagens desenvolvidos em cada projeto.

- Artigo [6]: "Machine Learning Approach to Predictive Maintenance in Manufacturing In-

dustry”

O artigo apresenta um estudo comparativo sobre a aplicação de técnicas de aprendizagem de máquina na manutenção preditiva na indústria. Há uma breve apresentação da evolução das estratégias de manutenção e um foco na manutenção preditiva apresentado essencialmente os benefícios desta abordagem. Foram introduzidas as importantes ”ferramentas”, e como conseguiram transportar os dados desde os sensores IOT, até as extensas clouds computacionais. As principais técnicas abordadas teoricamente foram as árvores de decisão e o algoritmo Random Forest, este ultimo foi aplicado a diferentes equipamentos, tais como: bombas industriais, maquinas de corte, sistemas de refrigeração, um motor de indução e uma turbina eólica. Em cada aplicação foram medidos vários aspetos, destacando-se a precisão e a acuricidade. O objetivo do estudo foi investigar e comparar diferentes algoritmos de aprendizagem de máquina utilizados para prever falhas em equipamentos industriais, com o intuito de melhorar a eficiência e reduzir os custos da manutenção. O autor procura identificar a abordagem mais eficaz para a previsão de falhas, permitindo que as empresas adotem medidas corretivas antes que ocorram falhas graves nos equipamentos.

- Artigo [7]: ”Previsão de falhas em empanques mecânicos da refinaria de Matosinhos usando modelos de Machine Learning”

Esta dissertação foi desenvolvida no âmbito do Mestrado Integrado em Engenharia Mecânica. O principal objetivo foi utilizar ferramentas de Machine Learning para prever falhas em empanques mecânicos. Foram utilizados dados recolhidos e armazenados continuamente, de uma refinaria de petróleo. Primeiramente, é apresentada a origem dos dados (software SAP e banco de dados RTDB). Em seguida, os registos do SAP são analisados e o modo de falha ”Vazamento de Empanque Mecânico” é identificado como o mais crítico (para um grupo de bombas centrífugas). Posteriormente, o modo de falha crítico é definido quantitativamente, o processamento dos dados é realizado e uma análise de falha de empanque mecânico é realizada, utilizando novas informações obtidas a partir dos sinais e registos existentes. Funções do Matlab foram desenvolvidas para obter estas informações. Por fim, são introduzidos conceitos de Machine Learning, apresentadas ideias sobre a aplicação de Machine Learning na manutenção e detalhados os principais resultados. O trabalho realizado permitiu concluir que a aplicação de ferramentas de Machine Learning na manutenção tem grande potencial e também permitiu desenvolver uma metodologia que pode apoiar projetos futuros.

- Artigo [8]: ”Procedimentos de Coletas de Óleo para Análise Preditiva de Turbinas à Gás”

Esta dissertação aborda os procedimentos de colheita de óleo para análise preditiva em turbinas a gás. Com o objetivo de prevenir falhas em equipamentos e reduzir os custos de manutenção, as turbinas a gás desempenham um papel crucial na indústria de petróleo e gás devido à sua capacidade de gerar energia cinética para acionar compressores e geradores. A formação de verniz no sistema de óleo, os custos de manutenção e a disponibilidade são preocupações importantes para garantir o bom funcionamento destas turbinas. Um planeamento de manutenção eficiente é essencial para otimizar custos e maximizar a disponibilidade des-

ses equipamentos. Neste contexto, a análise preditiva do óleo lubrificante desempenha um papel fundamental. Diversas técnicas são utilizadas, como análise de vibração, boroscópio, termografia e análise do óleo lubrificante. Neste trabalho, são apresentadas as técnicas utilizadas na análise preditiva de óleos lubrificantes e é fornecido um histórico de análises de óleo num caso real de uma turbina a gás. São discutidos os procedimentos ideais para coleta de amostras de óleo, desde o planeamento até ao envio para laboratórios, onde será feita a análise, verificação e diagnóstico das amostras.

O estudo destaca a importância da análise preditiva de óleo lubrificante como parte de um programa de manutenção eficaz, seguindo as recomendações do fabricante do equipamento. Esses procedimentos de recolha adequados das amostras de óleo permitem obter informações valiosas para a identificação precoce de possíveis falhas nas turbinas a gás, contribuindo para a otimização do funcionamento dos equipamentos e prolongamento de sua vida útil.

- Artigo [9]: "A Data-Centric Machine Learning Methodology: Application on Predictive Maintenance of Wind Turbines"

O objetivo deste artigo é contribuir para uma melhor compreensão do funcionamento das turbinas eólicas por meio de uma metodologia de aprendizagem de máquina. Em particular, foca na otimização das etapas de pré-processamento dos dados e na seleção de características do machine learning. A metodologia proposta é utilizada para detetar falhas que afetam cinco componentes num parque eólico composto por cinco turbinas. Apesar da simplicidade do modelo de machine learning utilizado (uma árvore de decisão), a metodologia superou a abordagem centrada no modelo (model-centric), melhorando a previsão da vida útil restante do parque eólico, tornando-o mais fiável e contribuindo para os esforços globais no combate às mudanças climáticas. É um artigo interessante para o trabalho desta dissertação, por abordar também os importantes tópicos: machine learning, manutenção preditiva e as turbinas eólicas.

- Artigo [10]: "Uma Abordagem para Manutenção Preditiva baseada em Sistemas Multiagente e Machine Learning"

Esta dissertação aborda a necessidade de adaptação dos sistemas industriais às mudanças do mercado, focando em enfrentar a competitividade e globalização crescentes. Com os avanços tecnológicos, a grande disponibilidade de sistemas de aquisição de dados e redes de computadores, as indústrias precisam de implementar metodologias de alta tecnologia para aumentar a flexibilidade e robustez dos sistemas de produção para reagir a situações inesperadas. A Manutenção Preditiva é considerada uma quebra de paradigma na manutenção, sendo cada vez mais intensificada à medida que a tecnologia avança. Esta abordagem é altamente confiável em termos de produção, pois monitoriza equipamentos e/ou sistemas, atuando quando necessário. No entanto, apesar dos equipamentos/sistemas serem capazes de detetar falhas, eles ainda dependem da intervenção humana para realizar as reparações. O objetivo deste trabalho é estudar como integrar Machine Learning em sistemas ciber-físicos. Esta abordagem tem como objetivo aprimorar a eficiência da Manutenção Preditiva, per-

mitindo que os sistemas tomem decisões mais inteligentes com base em análise de dados e aprendizagem automática. A combinação do poder dos sistemas multiagente, Machine Learning e serviços proporciona uma abordagem inovadora para a manutenção preditiva, aumentando a automação e reduzindo a dependência da intervenção humana.

- Artigo [11]: "Machine Learning for Predictive Maintenance on Wind Turbines"

Este trabalho explora a implementação de um sistema de manutenção preditiva para turbinas eólicas utilizando dados SCADA no Apache Spark. O estudo avalia como equilibrar e dimensionar o conjunto de dados, bem como os efeitos da aplicação dos algoritmos disponíveis no Spark MLlib para o problema em questão. Esses algoritmos incluem Perceptron Multicamadas (MLP), Regressão Linear (LR), Random Forest (RF), Árvore de Decisão (DT), Máquina de Vetor de Suporte (SVM) e Gradient Boosted Tree (GBT). Além disso, são avaliados os efeitos da aplicação de algoritmos de stacking e bagging na tentativa de reduzir a variância e melhorar as métricas do modelo.

A dissertação conclui que o MLP produz o modelo mais promissor para prever falhas no conjunto de dados fornecido e que empilhar vários modelos MLP é uma maneira eficaz de obter um modelo com menor variância, comparando com os modelos base individuais. Além disso, é desenvolvida uma função que cria uma estimativa da economia. Utilizando essa função, é criada uma função num intervalo de tempo que explora a capacidade de decisão de um modelo. Conclui que um modelo é mais decisivo se a falha que ele prevê ocorrer numa turbina em que foi treinado com dados de falha desse mesmo componente, o que indica a presença de variáveis desconhecidas que afetam os dados dos sensores.

- Artigo [4]: "Machine Learning approach for Predictive Maintenance in Industry 4.0"

Esta dissertação aborda a importância da monitorização do estado e da manutenção preditiva em motores elétricos e outros equipamentos utilizados na indústria para evitar perdas económicas devido a falhas inesperadas e melhorar significativamente a confiabilidade do sistema. O trabalho descreve uma arquitetura de Machine Learning para Manutenção Preditiva, baseada na abordagem Random Forest. O sistema foi testado num exemplo real da indústria, desenvolvendo a coleta e análise dos dados do sistema, aplicando a abordagem de Machine Learning e comparando-a com a análise de ferramentas de simulação.

Os dados foram coletados por vários sensores, CLPs de máquinas e protocolos de comunicação, tornando-os disponíveis para a análise de dados na arquitetura de nuvem Azure. Os resultados preliminares mostram um comportamento adequado da abordagem na previsão de diferentes estados das máquinas com alta precisão. Isso indica que a abordagem de Machine Learning utilizada é promissora para a manutenção preditiva na Indústria 4.0.

- Artigo [12]: "Real-Time Predictive Maintenance using Autoencoder Reconstruction and Anomaly Detection"

O objetivo desta dissertação é aprofundar a deteção de falhas em máquinas rotativas, que tradicionalmente dependem de testes de rotina para descobrir falhas, o que é um método

dispendioso e muitas vezes impulsivo. A monitorização em tempo real através de sensores oferece uma solução para detetar falhas sem a necessidade de observação manual. No entanto, a interpretação manual para deteção de anomalias é frequentemente subjetiva e varia entre os técnicos industriais. Este método é rígido e propenso a um grande número de falsos positivos. Para resolver esse problema, é proposta uma abordagem de Aprendizagem de Máquina para modelar a operação normal e detetar anomalias em tempo real. A abordagem extrai características importantes de dados que representam a operação normal conhecida, modelando o comportamento da máquina e identifica automaticamente anomalias. O ML aprende generalizações e gera limiares com base na gravidade da falha. Isto fornece aos engenheiros um sistema de semáforo em que o verde representa o comportamento normal, o amarelo indica preocupação e o vermelho significa uma falha da máquina. Esta escala permite que sejam adotadas medidas de intervenção precoces no momento apropriado.

A abordagem é avaliada em dados reais de sensores de máquinas em intervalos de tempo para observar o comportamento normal e anormal. Os resultados demonstram que é possível detetar anomalias dentro da faixa amarelo e emitir alarmes antes da falha da máquina. Isto possibilita medidas preventivas em estágios iniciais, evitando danos ou paragens indesejadas.

- Artigo [13]: "Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0"

Esta dissertação aborda a aplicação de técnicas de aprendizagem de máquina na manutenção preditiva para aprimorar a saúde dos equipamentos industriais na era da Indústria 4.0. Com a transformação digital e a implementação de sistemas inteligentes na Indústria 4.0, é possível coletar uma enorme quantidade de dados operacionais e condições de processos gerados por diversos equipamentos. Estes dados podem ser utilizados para realizar deteção e diagnóstico automático de falhas, permitindo minimizar o tempo de inatividade, aumentar a taxa de utilização dos componentes e prolongar a sua vida útil. A manutenção preditiva é essencial para uma produção inteligente e sustentável na Indústria 4.0.

As técnicas de aprendizagem de máquina têm sido amplamente aplicadas na manutenção preditiva, o que tem despertado o interesse de muitos pesquisadores nos últimos anos. Este trabalho classifica as pesquisas de acordo com os algoritmos de ML utilizados, a categoria de ML, as máquinas e os equipamentos utilizados, os dispositivos utilizados na aquisição de dados, a classificação dos dados, o tamanho e o tipo dos dados, destacando as principais contribuições dos autores. Além disso, são oferecidas diretrizes e uma base sólida para pesquisas futuras nesta área promissora.

A revisão destes artigos demonstra a ampla aplicação de técnicas de aprendizagem automática na manutenção preditiva. Estes estudos evidenciam os benefícios do uso de algoritmos de machine learning e na aquisição de dados na deteção e previsão de falhas em diferentes setores industriais. A análise destes trabalhos fundamenta e fornece informações relevantes para a investigação realizada nesta dissertação, permitindo a aplicação adequada de aprendizagem automática na manutenção

preditiva.

1.3 Objetivos

O objetivo principal desta dissertação consiste em aplicar ferramentas de Inteligência Artificial, mais especificamente de Aprendizagem de máquina (Machine Learning), a um conjunto de dados provenientes de diferentes turbinas, os quais são analisados em laboratório e disponibilizados pela Vestas. Pretende-se desenvolver um algoritmo capaz de classificar de forma mais rápida quais turbinas necessitam de manutenção, com o intuito de oferecer suporte à área de manutenção, principalmente em relação à sua gestão. Além disso, serão analisadas as particularidades dessa implementação e a definição de metodologias, com o objetivo de fornecer informações e ferramentas à área de manutenção.

1.4 Estrutura da Dissertação

A presente dissertação encontra-se dividida em quatro capítulos.

Neste primeiro capítulo (Capítulo 1) é realizada uma pequena introdução e enquadramento no estado de arte referente ao tema, bem como os objetivos propostos e trabalhos já realizados nesta área.

No Capítulo 2 é realizada uma revisão teórica, onde são apresentados os conceitos inerentes às energias renováveis, à manutenção e aos lubrificantes. É introduzido também o tema da Inteligência Artificial e realizada uma breve distinção entre Inteligência Artificial, Machine Learning e Deep Learning. Por fim, é apresentada a interligação entre a indústria e a inteligência artificial.

No Capítulo 3 são apresentados os resultados da aplicação de Machine Learning a um conjunto de dados interligados com a manutenção. É realizado um levantamento da origem dos dados, divisão e classificação, e ainda como estes se podem conjugar, através de feature engineering, de modo a aplicar os modelos de Machine Learning. Estuda-se ainda o processo de implementação do modelo.

No Capítulo 4 são apresentadas as conclusões finais do projeto e propostas de trabalho futuro.

Capítulo 2

Fundamentos

2.1 Introdução

No presente capítulo apresentam-se conceitos relacionados com as energias renováveis, turbinas eólicas, manutenção industrial e inteligência artificial. Este capítulo é de extrema relevância para o desenvolvimento da presente dissertação, uma vez que permite refletir sobre os conceitos adquiridos.

Recentemente, é possível observar um processo de mudança de mentalidade relativamente à forma como a manutenção é percebida, sendo-lhe atribuído um papel cada vez de maior relevância, pelo que, faz todo o sentido fazer o seu enquadramento.

2.2 Energias Renováveis

Nos dias de hoje, a energia é um bem essencial no desenvolvimento económico e social. De modo a que as gerações futuras possam ter acesso a este bem, a geração presente tem que ter o cuidado de não esgotar as fontes de energia. Assim, é essencial o desenvolvimento de tecnologias sustentáveis bem como uma utilização eficiente das tecnologias atuais. Além do risco de esgotamento das fontes tradicionais, também têm que ser tidas em conta questões ambientais. Na sua maioria, as fontes tradicionais são poluentes e não sustentáveis.

A sustentabilidade energética é a provisão de energia que corresponde às necessidades do presente sem comprometer as necessidades energéticas das gerações futuras. De um modo mais amplo, podemos permitir a inclusão dos combustíveis fósseis como fontes de energia enquanto desenvolvemos tecnologias, desde que essas novas tecnologias possam ser usadas pelas gerações futuras.

As fontes renováveis de energia são geralmente consideradas como fontes sustentáveis uma vez que permitem a sua renovação em tempo útil. Como fontes de energia renovável temos por exemplo a biomassa, o sol (energia solar), o vento (energia eólica), o mar (energia das ondas e a energia das marés) e a energia geotérmica. Para além do facto de que as fontes de energia não

sustentáveis correm o risco de se esgotarem, Portugal não é um país rico neste tipo de recursos. Assim, a produção de energia primária depende fortemente de importações e dos preços do mercado. As energias renováveis são portanto um modo de combater esta dependência energética porque, como já referimos, as fontes de energia renovável não se esgotam.

2.2.1 Energia Eólica

Energia eólica é o nome que se dá à energia elétrica gerada a partir da força dos ventos. Uma vez que a sua produção utiliza um recurso natural inesgotável, a eólica é considerada um tipo de energia renovável. A estrutura em que ocorre a conversão da energia cinética em eletricidade é o aerogerador ou turbina eólica. Trata-se de uma energia consideravelmente mais barata do que as outras e não emite poluentes para a atmosfera. Por outro lado, as estruturas instaladas causam ruídos e impactam diretamente a fauna local, podendo também levar à morte de aves.

A energia eólica é produzida pela força dos ventos num processo de conversão de energia cinética (proveniente do movimento) em eletricidade. Isto é possível devido às turbinas eólicas ou aerogeradores, que se assemelham aos moinhos de vento e formam os parques eólicos, cuja paisagem já nos é bastante familiar.

O vento faz com que as pás rodem a uma velocidade que varia em média de 10 a 30 rotações por minuto (rpm), acionando o rotor (estrutura na qual as pás estão conectadas). O movimento do rotor é multiplicado no interior da nacele (pela caixa de velocidades), a estrutura retangular que fica posicionada atrás das pás e na qual está conectada a torre da turbina. No interior da nacele, fica o gerador, responsável pela conversão da energia cinética em energia elétrica.

Tal como indica a figura 2.1, depois de produzida, a eletricidade é conduzida por cabos elétricos para transformadores antes de ser enviada à rede. No final, a rede de distribuição faz com que a energia eólica seja distribuída para os consumidores finais.




Figura 2.1: Distribuição de Energia Eólica.

Vantagens da Energia Eólica

Uma das principais vantagens da energia eólica é o facto de ser gerada a partir de uma fonte renovável, o vento. Além disso, é considerada uma forma de energia limpa, uma vez que não emite poluentes diretamente para a atmosfera durante o seu processo de produção.

Os custos de instalação e manutenção de um parque eólico têm vindo a diminuir progressivamente nos últimos anos, o que torna a energia eólica cada vez mais competitiva nos mercados internacionais e, futuramente, mais economicamente vantajosa quando comparada com outras formas de energia, como a hidroelétrica.

Outra vantagem da energia eólica é o facto de ser cada vez mais utilizada como uma alternativa às energias mais poluentes, como as derivadas de combustíveis fósseis, contribuindo para uma produção de energia mais "limpa" e sustentável.

Desvantagens da Energia Eólica

Assim como outros tipos de energia, a energia eólica apresenta desvantagens. Embora o impacto ambiental seja menor em comparação com outras fontes, as turbinas eólicas representam um perigo real para animais, como as aves, que muitas vezes colidem com as torres ou são mortas ao voarem em direção às pás em movimento. Não apenas as aves locais são afetadas por essas estruturas, mas também as espécies migratórias que se deslocam periodicamente.

As turbinas eólicas em funcionamento produzem um ruído elevado, o que pode ser caracterizado como poluição sonora, causando desconforto às populações que vivem nas proximidades dos parques. Além disso, outro aspeto negativo dos parques eólicos é a poluição visual.

Além disso, a energia eólica depende diretamente de um fenómeno natural. Portanto, a instalação dos parques é seletiva em termos de localização, pois precisa de uma alta incidência de ventos - ou seja, não pode ser feita em qualquer lugar. A produção também é irregular, já que os ventos não sopram constantemente nem com a mesma intensidade.

Por último, embora os custos de instalação tenham diminuído com a maior adesão e concorrência na energia eólica, eles ainda se mantêm em um patamar elevado, o que a torna uma opção cara.

É importante ressaltar que essas são algumas das desvantagens associadas à energia eólica, mas é fundamental considerar que muitas delas podem ser mitigadas por meio de tecnologias e práticas adequadas de planeamento e monitorização ambiental.

2.2.2 Tipos de Turbinas Eólicas

Turbinas de eixo vertical

Uma turbina eólica de eixo vertical é essencialmente uma turbina na qual o eixo do rotor é instalado na vertical, permitindo gerar eletricidade independentemente da direção do vento. A vantagem deste tipo de turbina é a capacidade de gerar eletricidade mesmo em locais com pouco

vento e áreas urbanas onde as regulamentações de construção frequentemente proíbem a instalação de turbinas eólicas horizontais.

As turbinas eólicas de eixo vertical não requerem um mecanismo de orientação e o gerador elétrico pode ser posicionado no solo. No entanto, é importante destacar que a produção de energia dessas turbinas é geralmente menor em comparação com as turbinas de eixo horizontal. Além disso, elas possuem algumas pequenas limitações, como a necessidade de serem motorizadas para iniciar o funcionamento.

Apesar dessas limitações, as turbinas eólicas de eixo vertical podem ser uma opção interessante em determinados contextos, especialmente onde as condições de vento são menos favoráveis ou onde as restrições são um obstáculo para a instalação de turbinas de eixo horizontal. É importante considerar as características específicas do local e as necessidades energéticas ao avaliar a viabilidade e o desempenho das turbinas eólicas de eixo vertical.




Figura 2.2: Turbina de eixo vertical.

Turbinas de eixo horizontal

As turbinas de eixo horizontal são as mais utilizadas e são encontradas nos grandes parques eólicos.

Essencialmente, uma turbina de eixo horizontal é uma máquina rotativa em que o movimento é gerado pela energia cinética do vento atuando sobre um rotor que geralmente possui três pás. O movimento rotacional resultante é transmitido e amplificado através de uma caixa de velocidades até ao gerador responsável pela produção de energia elétrica.

Cada turbina eólica possui um controlador que é responsável por controlar e regular as suas

variáveis através dos dados fornecidos pelos sensores, permitindo que a turbina se adapte e responda em tempo real.

A energia obtida de uma turbina eólica depende da força do vento que passa pelas pás e é diretamente proporcional à: densidade do ar, área das pás e velocidade do vento.

É importante ressaltar que as turbinas de eixo horizontal são projetadas para capturar a máxima quantidade de energia do vento numa faixa específica de velocidades. Elas são mais eficientes em velocidades do vento moderadas a altas, enquanto que em velocidades muito baixas ou muito altas, a produção de energia pode ser reduzida. Além disso, é essencial considerar fatores como a localização do parque eólico, a direção predominante do vento e as características específicas do terreno ao planejar a instalação das turbinas.




Figura 2.3: Turbina de eixo horizontal.

Estrutura das Turbinas Eólicas

Como já foi mencionado, existe alguma variedade de turbinas eólicas disponíveis no mercado, cada uma com sua estrutura característica. Agora, irão ser mencionados alguns dos componentes dos aerogeradores de eixo horizontal, que são os mais utilizados, especialmente em termos de produção em larga escala e nos quais são baseados os dados utilizados neste trabalho.




Figura 2.4: Estrutura de uma turbina eólica de eixo horizontal.

Torre

É o maior componente da turbina eólica (ilustrado na figura 2.4 como: Tower), serve para dar sustentação ao restante equipamento. Também tem a função de posicionar a nacelle que fica sobreposta à estrutura.

Rotor

O rotor (ilustrado na figura 2.4 como: Rotor) é composto pelas pás (geralmente três) do equipamento e pelo cubo (parte que une as pás), permitindo assim a obtenção da energia mecânica dos ventos por meio da rotação. Essa energia é transmitida através do eixo central, que por sua vez está conectado à caixa de transmissão. Na maioria dos casos, o rotor possui um diâmetro de 60m a 150m e conta com um sistema que permite variar a posição das pás (ilustrado na figura 2.4), permitindo capturar melhor os ventos ou até mesmo interromper o movimento.

Pás

As pás (ilustrado na figura 2.4 como: Blades) são perfis aerodinâmicos projetados de forma a garantir a melhor obtenção da energia do vento. E para isso, elas são produzidas com materiais leves e resistentes, como a fibra de vidro ou de carbono.

Nacelle

Esta é a parte mais pesada da estrutura (ilustrado na figura 2.4 como: Nacelle), chegando a pesar mais de 100 toneladas em alguns casos. Por isso uma boa logística dos transportes é fundamental, para ser possível fazer estes componentes não só chegar a locais remotos onde os parques são estabelecidos, como também elevá-la até o topo da torre. Nesta cabine, estão reunidas várias

partes do aerogerador, como caixa de transmissão, transformador, etc. Ela funciona como uma estação de operação e manutenção onde os técnicos entram e realizam a maioria das intervenções.

Caixa de transmissão

Também conhecida por gearbox (ilustrado na figura 2.4 como: Gearbox), é aqui onde acontece o aumento da velocidade que vem do rotor, para uma velocidade na qual o gerador possa produzir eficientemente e em segurança. O equipamento é constituído por um conjunto de engrenagens, que juntas, conseguem um fator multiplicador, elevando rotações baixas e fornecendo ao eixo um aumento significativo que permite o bom e eficiente funcionamento do gerador.

Gerador

Este é o dispositivo (ilustrado na figura 2.4 como: Generator) responsável pela conversão da energia mecânica de rotação do eixo, em energia elétrica. Fica instalado no interior da nacelle e pode ser basicamente de dois tipos:

- **Síncrono:** velocidade de rotação é proporcional à frequência da tensão na qual ele está conectado.
- **Assíncrono:** velocidade de rotação não é proporcional a essa frequência.

Anemómetro

Este sensor (ilustrado na figura 2.4 como: Anemometer) é utilizado para fazer medições da velocidade do vento no local. Para isto, ele fica posicionado na nacelle, com o objetivo de captar com maior fidelidade os ventos que chegam até o rotor do aerogerador. Com estes dados, é possível gerar os gráficos da curva de potência das turbinas e realizar estudos da eficiência de produção dos parques.

Biruta

Este sensor (ilustrado na figura 2.4 como: Wind vane) fica junto do anemómetro e a sua função é medir qual a direção do vento. Ao enviar estas informações para o sistema de controlo (ilustrado na figura 2.4 como: Controller), as ações podem ser tomadas em tempo real. Isto vai auxiliar na operação do parque eólico, possibilitando que a nacelle rode, através de um motor (ilustrado na figura 2.4 como: Yaw motor) e direcione o rotor para onde o vento está mais forte.

2.3 Manutenção Industrial

As práticas atuais de manutenção industrial têm incorporado, às suas estratégias usuais de gestão, alguns conceitos originados na confiabilidade. A manutenção tem procurado novos modos de pensar, técnicos e administrativos, já que as novas exigências de mercado tornaram visíveis as limitações dos atuais sistemas de gestão. Uma das modificações é a incorporação de elementos da confiabilidade às estratégias usuais de manutenção encontradas nas empresas de fabricação e

de serviços tecnológicos. Há varias opiniões relativas à classificação das estratégias de manutenção, por isso decidiu-se uma única tipologia: (i) a emergência opera até a falha, reparando o item que falhou; (ii) a corretiva opera até a falha, reforçando ou corrigindo o item que falhou; (iii) a preventiva, executa intervenções incondicionais constantes de um programa pré-agendado; e (iv) a preditiva executa intervenções baseadas em diagnósticos.

O avanço do planejamento de manutenção é uma necessidade para serviços públicos, industriais, produtores independentes de energia e operadores de instalações de cogeração, com o objetivo de minimizar o tempo de inatividade dos equipamentos, ou seja, um aumento da disponibilidade e aumento da confiabilidade. Os principais fatores que afetam o processo de planejamento de manutenção são listados em baixo, assim como o modo de operação irá determinar como cada fator é ponderado.

- Características do projeto.
- Ciclo de trabalho.
- Custo do trabalho de manutenção.
- Tipo de combustível.
- Disponibilidade da peça para reposição.
- Requisitos de reserva.
- Meio ambiente.
- Necessidade de utilização.
- Capacidade de manutenção local.
- Necessidade de confiabilidade.
- Especialista em diagnósticos e processos.
- Procedimentos de manutenção recomendado pelo fabricante.

Como falado anteriormente podemos entender manutenção como o conjunto de cuidados e procedimentos técnicos necessários ao bom funcionamento e também ao reparo de máquinas, equipamentos, peças, moldes e ferramentas. A palavra, derivada do latim *manus tenerem* que significa "manter o que se tem", também é definida de diferentes maneiras por muitos órgãos certificadores e normalizadores, porém sempre destacando a preocupação com o bom funcionamento das máquinas e dos equipamentos, principalmente em sistemas de produção. Assim como as máquinas, as ferramentas, os materiais e a tecnologia evoluíram desde o surgimento da Mecanização, Industrialização e Automatização, a Manutenção também evoluiu, não só no que se refere aos procedimentos práticos de montagem, desmontagem, substituição de peças e alinhamento, mas principalmente na "Gestão da Manutenção" e no desenvolvimento dos tipos de manutenção que antedessessem a cada necessidade industrial. Surgiram então três principais tipos de Manutenção:

- **Corretiva;**

-
- **Preventiva;**
 - **Preditiva.**

2.3.1 Manutenção Corretiva

A manutenção corretiva é um conjunto de procedimentos que são executados com a finalidade de auxiliar imediatamente a produção, a máquina ou o equipamento que parou. A equipe de manutenção age imediatamente para restabelecer o seu funcionamento o mais rápido possível. Nem sempre o "mais rápido possível" ocorre em tempos de se evitar os prejuízos causados por uma paragem de máquina inesperada. Alguns casos específicos permitem a utilização da manutenção corretiva para otimizar um processo ou por questões económicas, porém de maneira organizada e tecnologicamente administrada.

2.3.2 Manutenção Preventiva

A manutenção preventiva é planeada e controlada, realizada em datas predeterminadas, de modo a manter a máquina ou o equipamento em corretas condições de funcionamento e conservação, evitando paragens imprevistas. O planeamento é possível utilizando a documentação relativa às operações de manutenção corretivas realizadas e informações sobre a vida útil das peças, fornecidas pelo fabricante.

Vantagens da Manutenção Preventiva

- **Equilibrar a utilização de recursos humanos:** planeando as operações de manutenção, é possível criar um ritmo de trabalho constante e prever a quantidade de técnicos no setor de manutenção, eliminando tempos ociosos e excesso ou falta de profissionais.
- **Eliminar tempos de espera na compra de peças:** com o cronograma de manutenção preventivo é possível fazer uma precisão do consumo de peças e despesas provenientes das operações de manutenção, o que evita stocks desnecessários ou falta de peças que causam a paragem da máquina até a compra e recebimento da peça.
- **Confiabilidade de prazos no sistema de produção:** a manutenção preventiva permite o bom funcionamento das máquinas utilizadas em sistemas de produção de uma empresa, o que evita atrasos ou esperas por falha das máquinas.
- **Satisfação do cliente:** a manutenção preventiva contribui para o cumprimento dos prazos de entrega do produto e para a qualidade do mesmo, proveniente de máquinas mantidas em perfeito estado de funcionamento, refletindo-se na satisfação dos clientes.
- **Gestão ambiental:** uma grande preocupação mundial é o impacto ambiental gerado por resíduos resultantes dos processos industriais. Neste contexto, a manutenção preventiva deveria estar direcionada para os equipamentos anti-poluição, ou seja, atuando eficientemente em problemas tais como: vazamento de fluidos, excesso de emissão de gases, etc...

2.3.3 Manutenção Preditiva

A manutenção preditiva é um método que usa dados e tecnologias para prever falhas em equipamentos antes que elas ocorram, permitindo que as empresas evitem paragens não programadas e reduzam o tempo de inatividade. Em baixo irão ser citadas algumas das técnicas relativas a este tipo de manutenção:

- **Análise de vibração:** a análise de vibração é uma técnica que usa sensores para monitorizar a vibração de componentes mecânicos e identificar desgaste ou problemas iminentes. A análise de vibração pode ser usada em diversos tipos de equipamentos, incluindo turbinas, motores e bombas.
- **Análise de óleo:** a análise de óleo é uma técnica que usa a análise química e física do óleo para identificar desgaste ou contaminação de componentes mecânicos. No presente trabalho são os resultados destas análises que irão ser utilizados para treinar o algoritmo de inteligência artificial.
- **Termografia:** é uma técnica que usa câmaras infravermelhas para detetar pontos quentes ou frios em equipamentos elétricos e mecânicos. Isto pode indicar problemas como sobrecarga ou mau funcionamento de componentes.
- **Inspeção visual:** é uma técnica que envolve a inspeção visual dos equipamentos para identificar sinais de desgaste, corrosão ou outros problemas visíveis. Esta técnica é principalmente usada em equipamentos como tubagens e estruturas.
- **Monitorização:** é uma técnica que envolve o uso de sensores para monitorizar variáveis como temperatura, pressão, humidade e vibração, com o objetivo de identificar desvios dos valores predefinidos. Isto pode indicar problemas em componentes específicos dependendo da localização dos sensores.

Cada tipo de manutenção preditiva tem vantagens e desvantagens, e a escolha da técnica mais adequada depende das características do equipamento e das necessidades específicas.

2.3.4 Falha, Avaria e Modo de Falha

Falha, avaria e modo de falha são termos frequentemente usados no contexto da engenharia, especialmente em relação a sistemas, máquinas e equipamentos. Embora estejam relacionados, eles têm significados ligeiramente diferentes [14].

- **Falha:** ocorre quando um sistema, componente ou subsistema não realiza a função pretendida (quando algo não está a funcionar como deveria). A falha pode resultar em: mau desempenho, interrupção parcial ou total da operação, ou até mesmo na inoperância completa do sistema. Por exemplo, uma lâmpada que não acende ou um motor que não liga, estão a apresentar falhas.
- **Avaria:** refere-se a um defeito físico, dano ou mau funcionamento de um componente específico. É a manifestação visível de uma falha. A avaria pode ser causada por desgaste,

fadiga, quebra, corrosão, sobrecarga, entre outros fatores. Por exemplo, se uma peça mecânica quebra num sistema, essa é a avaria específica que ocorreu.

- **Modo de falha:** é a maneira específica pela qual um sistema ou componente falha. É uma descrição detalhada do processo ou sequência de eventos que levam à falha. O modo de falha pode ser uma característica inerente de um componente ou pode ocorrer devido a condições externas. Por exemplo, o modo de falha de um sistema elétrico pode ser um curto-circuito, enquanto o modo de falha de um sistema hidráulico pode ser uma falha na vedação.

Em resumo, a falha é a não realização da função pretendida, a avaria é o defeito ou dano físico que ocorre como resultado da falha, e o modo de falha é a descrição específica do processo ou eventos que levam à falha. Estes conceitos são normalmente usados na análise de falhas e na engenharia de confiabilidade para identificar e corrigir problemas em sistemas e equipamentos.

2.3.5 Curva PF

A curva PF (Potencial de Falha) é uma representação gráfica que descreve a relação entre o tempo de vida útil de um equipamento e o seu tempo de falha potencial. É muito utilizada na área de manutenção para avaliar o desempenho e o estado dos equipamentos ao longo do tempo.

Como observamos na figura (figura 2.5) a curva PF é composta por dois pontos principais: o ponto P (Potencial failure) e o ponto F (Functional failure). À medida que o tempo avança, a linha começa a declinar gradualmente, indicando uma degradação progressiva e o surgimento de sinais de falha.

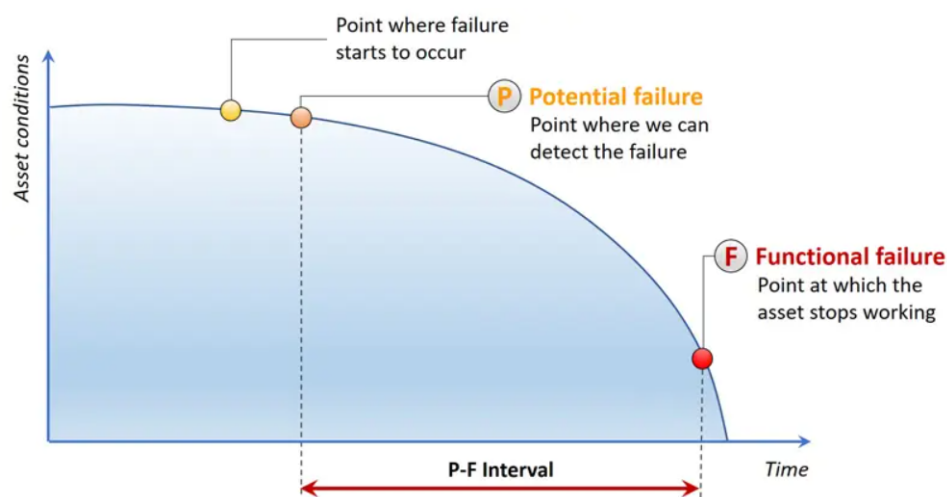


Figura 2.5: Curva-PF.

- **Ponto P (potencial):** podemos chamá-la de modo de falha ou sintoma. É o momento em que a falha ocorre no equipamento, estando no seu estágio inicial, é detetável. Ela não compromete o funcionamento total do equipamento, mas faz com que sua performance desça. Por exemplo, um aumento na temperatura de um sensor; um aumento ou redução de pressão num sistema hidráulico; um aumento dos níveis de ruído ou uma vibração.

- **Ponto F (funcional):** ao contrário da potencial, a falha funcional caracteriza-se por ocasionar a incapacidade do equipamento em continuar a exercer as suas funções de maneira eficaz e satisfatória. Uma falha funcional inclui a incapacidade de funcionar no nível de desempenho em que foi especificado como ideal e/ou satisfatório. Por exemplo, quando um fusível queima; o ativar de um disjuntor; gripagem dos rolamentos; desalinhamento dos eixos ou rompimento de mangueiras pneumáticas, ou hidráulicas.

Ter conhecimento sobre os tipos de falhas e o momento em que elas ocorrem, é indispensável para que a equipa de manutenção consiga identificar qual a fase em que a falha está. Os softwares de monitorização remotos são excelentes ferramentas para auxiliar nesse processo. Com esta informação, é possível gerir o risco da falha e evitar que o equipamento evolua de uma falha potencial para funcional, correndo o risco de causar uma paragem na produção.

Analisando o gráfico 2.6 podemos ver que o eixo horizontal (x) representa o tempo de serviço de um equipamento ou componente. Já o eixo vertical (y) representa o desempenho ou performance. A curva PF identifica como o desempenho ou a condição do componente diminui ao longo do tempo, considerando a falha funcional, ou seja, a perda de função para onde se destinava.

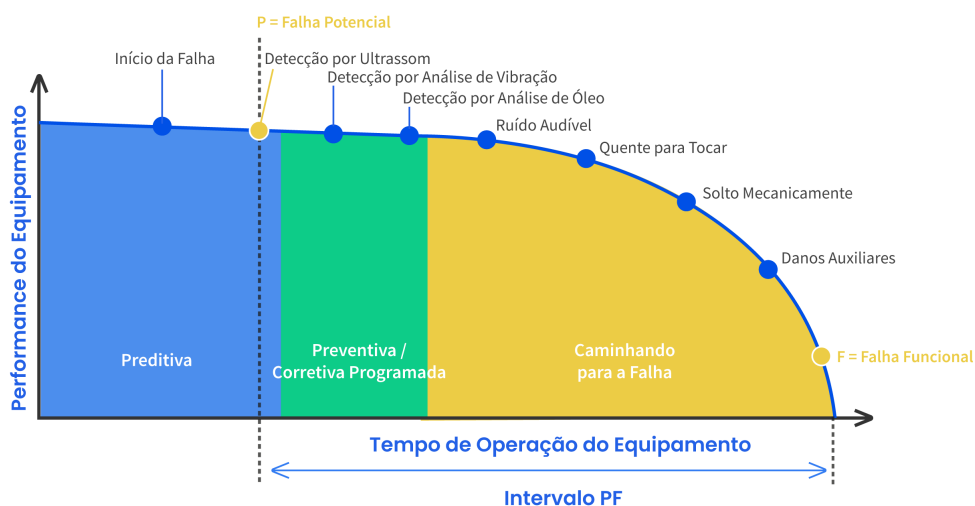


Figura 2.6: Anomalias na curva PF.

Neste caso, a equipa de manutenção pode aplicar técnicas preditivas para conseguir identificar a falha potencial antes de causar uma paragem inesperada, tais como:

- **Deteção de vibração:** mesmo que no estágio inicial da falha, a análise de vibração permite que seja possível identificar qualquer desvio nos parâmetros normais do equipamento. Cada elemento tem uma frequência de vibração, gerando um ruído característico que se torna próprio no espectro de vibração.

Caso seja encontrado algum dano, o padrão irá se alterar e permitirá que o profissional o reconheça, como por exemplo, se o problema é proveniente de um desalinhamento do eixo, falha de lubrificação ou possíveis danos no rolamento. Além do diagnóstico precoce e preciso, também

é possível quantificar o nível da falha e determinar se é necessária uma ação imediata ou se pode esperar até a próxima manutenção.

- **Deteção por análise de óleo:** esta é uma ferramenta da manutenção preditiva que permite que sejam realizadas avaliações laboratoriais rápidas e precisas sobre o lubrificante utilizado nos equipamentos. A análise de óleo permite que seja possível detetar tanto o desgaste das peças dos equipamentos, quanto a presença de substâncias contaminantes.

Depois do diagnóstico feito, a equipa de manutenção consegue identificar com mais agilidade e até mesmo antecipar possíveis falhas, evitando que o desempenho do serviço e/ou a qualidade do produto seja comprometido.

Uma boa programação da análise de lubrificantes pode ser uma excelente ferramenta para a gestão de equipamentos. Saber com precisão quando deverá acontecer a próxima troca de óleo e emitir ordens de serviço é indispensável para eliminar os problemas incomuns mais dispendiosos e quebras de produção indesejadas.

- **Ruídos:** quando um equipamento emite ruídos que são possíveis de ouvir pelo humano sem nenhum equipamento, a falha já está avançada e numa fase de perigo. A oportunidade de detetar a falha num estágio inicial com alarmes gerados automaticamente é mais alta, além de possibilitar a criação de ordens de serviço para organizar e fazer uma melhor gerência da planta dos equipamentos.

Quanto maior o tempo para identificar e solucionar a falha, maior será o custo da reparação. A curva de custos é inversamente proporcional à curva PF.

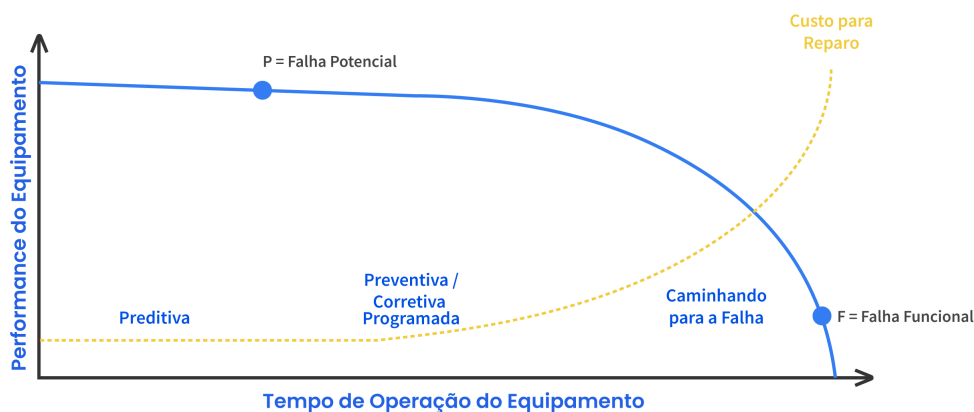


Figura 2.7: Relação entre a Curva PF e a Curva de custos.

2.3.6 Manutenibilidade

A manutenibilidade¹ é definida como a aptidão de um bem, sob condições de utilização definidas, para ser mantido ou restaurado, de tal modo que possa cumprir uma função requerida, quando a manutenção é realizada em condições definidas, utilizando procedimentos e recursos prescritos.

¹Qualidade ou característica do que pode ser mantido ou alvo de manutenção.

É quantificada pelo parâmetro de **MTTR**, que representa a média de tempo que leva a reparação dos equipamentos, na qual o intervalo de tempo considerado é entre a detecção de uma falha até à retoma das suas funções.

$$MTTR = \frac{\sum TTR}{N} \quad (2.1)$$

Onde:

- **MTTR** - Tempo Médio de Reparação;
- **TTR** - Tempo de Reparação;
- **N** - número de reparações no período de tempo considerado.

2.3.7 Fiabilidade e Disponibilidade

Define-se fiabilidade como a aptidão de um bem para cumprir uma função requerida sob determinadas condições, durante um dado intervalo de tempo. A fiabilidade também se pode aplicar como uma medida de desempenho da fiabilidade, podendo, nesse caso, definir-se como uma probabilidade. O processo de resolução de problemas de fiabilidade deve começar por um conhecimento profundo dos equipamentos que se pretende analisar e respetivas condições de funcionamento. De modo a quantificar a fiabilidade, é utilizado o parâmetro **MTBF**.

$$MTBF = \frac{\sum TBF}{N} \quad (2.2)$$

Onde:

- **MTBF** - Tempo Médio entre Falhas;
- **TBF** - Tempo entre Falhas: o intervalo de tempo que decorre entre duas falhas consecutivas num determinado equipamento;
- **N** - número de falhas verificadas no período.

Outro parâmetro associado ao **MTBF** é a taxa de falhas (λ) - que pode ser definida como a razão entre o número de falhas, n , e o produto entre um determinado intervalo de tempo, τ , e o número de equipamentos sobre o qual incide a análise. Este parâmetro quantifica a frequência média de falhas por equipamento. Desta forma, tem-se que:

$$\lambda = \frac{n}{m} \quad (2.3)$$

A análise da fiabilidade envolve não só a análise do **MTBF** dos equipamentos, mas também o modo de degradação dos mesmos. Esta degradação influencia a evolução da taxa de falhas ao longo do tempo, normalmente representada pela denominada curva da banheira (figura 2.8).

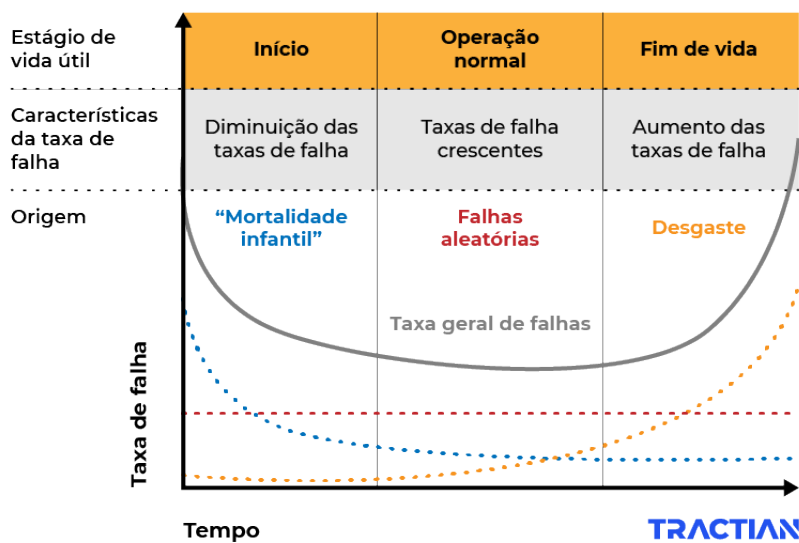


Figura 2.8: Curva da banheira.

A curva da banheira representa três períodos distintos da vida de um equipamento:

1. **Início:** a taxa de falhas é mais elevada, sendo que depois decresce e tende a estabilizar;
2. **Operação normal:** as falhas são aleatórias, com taxa de falhas baixa e aproximadamente constante;
3. **Fim de vida:** a taxa de falhas aumenta de uma forma acentuada, devido a fatores como a acumulação de danos, fadiga ou degradação.

A disponibilidade (**D**) representa a aptidão de um bem para cumprir uma função requerida sob determinadas condições, num dado instante ou durante um dado intervalo de tempo, assumindo que é assegurado o fornecimento dos necessários recursos externos. A disponibilidade é uma função direta da fiabilidade e da de manutibilidade.

$$D = \frac{MTBF}{MTBF + MTTR} \times 100\% \quad (2.4)$$

Onde:

- **D** - Disponibilidade, geralmente expressa em percentagem;
- **MTBF** - Tempo Médio entre Falhas;
- **MTTR** - Tempo Médio de Reparação.

Apesar de ser importante definir fiabilidade e disponibilidade de forma bastante precisa, o processo de avaliação do desempenho e do cumprimento de metas impostas na manutenção, envolve necessariamente a definição de métricas que permitam avaliar quantitativamente a fiabilidade e a disponibilidade dos equipamentos, quantificar o que se faz, estabelecer os objetivos do que se

pretende fazer e ainda quantificar o que se conseguiu de facto fazer. A definição de indicadores apropriados, que medem os resultados atuais e esperados desta área, permite perceber o valor criado pelos processos de manutenção e ainda quantificar se o investimento realizado está a produzir mais valias para a organização. Mais ainda, em manutenção, não é possível definir um número de indicadores necessários para medir ou fundamentar decisões da gestão universais, sendo que, em cada caso será importante perceber quais os indicadores que podem ser utilizados, adaptados ou até mesmo criados especificamente para uma determinada aplicação.

2.3.8 Gestão da Manutenção

A gestão da manutenção é uma atividade dinâmica que envolve funções como o planeamento, a coordenação, a monitorização e o controlo de recursos. Neste sentido, a manutenção pode ser considerada como uma atividade de apoio à produção, uma vez que contribui para uma melhoria da operacionalidade dos equipamentos. Ainda assim, é muitas vezes designada como um mal necessário para a empresa, pois possui sempre um determinado custo associado, além de forçar a paragem de equipamentos e, conseqüentemente, da produção. No entanto, atualmente, a manutenção pode ser um fator estratégico para garantir alta produtividade de sistemas industriais. É, portanto, fundamental desenvolver estratégias de gestão de manutenção. [15]

A gestão da manutenção define-se como o conjunto das atividades de gestão que estabelecem os objetivos, a estratégia e as responsabilidades da manutenção, e que procedem à sua implementação através do planeamento, controlo e supervisão desta e da melhoria contínua dos métodos da organização, incluindo os fatores económicos. Na Figura 2.9 estão representadas as principais funções da gestão da manutenção.

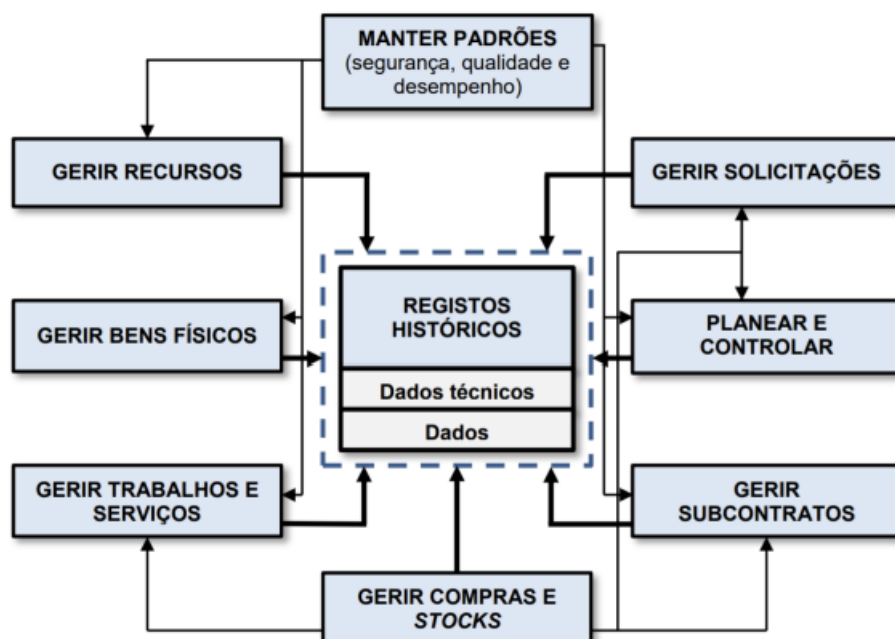


Figura 2.9: Gestão da manutenção.

A gestão da manutenção é fundamental para a produtividade de uma empresa, otimização dos custos e, principalmente, preservação dos equipamentos.

2.4 Lubrificantes e Técnicas de Análise de óleo lubrificante

2.4.1 Lubrificantes

Quando ocorre um movimento relativo entre superfícies é normalmente desejável minimizar a fricção e o desgaste. Qualquer substância interposta que reduz a fricção e desgaste é um lubrificante.

A lubrificação pode ser feita de muitas formas diferentes, dependendo da geometria dos corpos em contacto, da aspereza e textura das superfícies deslizantes, da carga, da pressão, da temperatura, das rotações de rolamento e nível de fricção, das condições ambientais, das propriedades físicas e químicas do lubrificante, da composição do material, e das propriedades das camadas superficiais das peças. Duas outras funções importantes dos lubrificantes são a proteção contra corrosão e auxílio à vedação.

- **Redução do atrito:** A função primária do lubrificante é formar uma "película" entre duas superfícies móveis, reduzindo o atrito e suas consequências, que podem levar à quebra dos componentes.
- **Refrigeração:** O óleo lubrificante representa um meio de transferência de calor. Nos motores de combustão interna, o calor é transferido para o óleo através de contactos com vários componentes, e então, para o sistema de arrefecimento de óleo.
- **Limpeza:** Nas turbinas eólicas uma das funções do lubrificante é retirar as partículas resultantes do processo de fricção das engrenagens mantendo estas partículas em suspensão no óleo, evitando que se depositem no fundo do tanque e provoquem incrustações.
- **Proteção contra a corrosão:** A corrosão e o desgaste podem resultar na remoção de metais da turbina, por isso a importância dos aditivos anticorrosivo e anti desgaste.
- **Vedação:** O lubrificante ao mesmo tempo em que lubrifica e refrigera, também age como agente de vedação, impedindo a saída de lubrificante e a entrada de contaminantes externos aos compartimentos das turbinas.

Dentro dos vários tipos de lubrificantes será dada atenção aos lubrificantes líquidos utilizados em turbinas eólicas. Uma forma de caracterizar os lubrificantes líquidos é através de sua viscosidade. Os lubrificantes são subdivididos de acordo com a sua base de formulação como:

- **Minerais:** São óleos obtidos a partir da destilação do petróleo. As suas propriedades dependem da natureza do óleo cru, cuja composição, muito variada, é formada por um grande número de hidrocarbonetos, pertencentes a três classes: parafínicos, naftênicos e aromáticos. Os óleos minerais são os mais utilizados e importantes em lubrificação.

- **Graxos:** São óleos de origem vegetal ou animal. Foram os primeiros lubrificantes a serem utilizados, e satisfaziam as modestas necessidades da época em que predominava a tração animal. Atualmente são pouco recomendados, principalmente por não suportarem temperaturas elevadas, oxidando-se facilmente, tornando-se rançosos e formando ácidos.
- **Aditivados:** Os óleos aditivados são óleos minerais puros ou sintéticos, aos quais foram adicionadas substâncias chamadas de aditivos, com o fim de reforçar ou acrescentar determinadas propriedades.
- **Compostos:** São misturas de óleos minerais e graxos. Certas aplicações especiais requerem muitas vezes o uso de óleos compostos, que conferem ao produto obtido maior oleosidade e maior facilidade de emulsão na presença de vapor. Geralmente são utilizados em equipamentos como perfuratrizes e cilindros a vapor.
- **Sintéticos:** São lubrificantes desenvolvidos em laboratório por processo de polimerização, especialmente para oferecer características especiais de viscosidade e resistência a temperaturas elevadas ou muito baixas, de forma a atender aplicações especiais em algumas indústrias. Esses lubrificantes são de custo elevado, devendo, ser utilizados apenas em casos específicos que não possam ser atendidos pelos lubrificantes minerais.

Mesmo que não ocorra nenhum acidente durante o funcionamento do equipamento, por exemplo o rompimento de mangueiras ou falha em trocadores de calor, o óleo está em constante deterioração. Isto ocorre devido ao desgaste dos componentes ou contaminação por água (condensação da humidade do ar), ou alteração da acidez por conta de pontos de calor e mesmo a sua deterioração com conseqüente formação de lacas e vernizes.

O óleo lubrificante de redutores, multiplicadores, turbinas entre outros também se deteriorará com o passar do tempo (geralmente em pouco tempo). O óleo é exposto ao desgaste dos componentes que se tocam durante a transmissão de energia.

Propriedades fundamentais

Podem ser destacadas algumas propriedades e características de um óleo lubrificante que interferem diretamente no seu desempenho e na sua qualidade de lubrificação no interior de uma turbina, tais como:

- Viscosidade;
- Índice de viscosidade;
- Densidade.
- Ponto de fulgor;
- Ponto de fluidez;
- TAN/TBN.
- Oxidação;

-
- Formação de Espuma;
 - Arrasto do Ar.

2.4.2 Análise de óleo lubrificante

A prática da análise de óleos em serviço ou da análise de óleos usados é bastante antiga, tendo-se iniciado há mais de um século em motores de locomotivas. Hoje em dia, é um dos componentes mais importantes da designada manutenção de condição, uma prática que consiste em avaliar a condição de uma máquina reunindo periodicamente dados sobre os principais indicadores de integridade da mesma, permitindo assim determinar os agendamentos de manutenção.

A análise físico-química de óleo lubrificante ou hidráulico, traz benefícios para o equipamento da mesma forma que a análise de sangue traz para o corpo humano. Deve ser analisado periodicamente para que possamos verificar como está a "saúde" do equipamento.

Num sistema hidráulico, a função do óleo é a condução de energia, além de promover a lubrificação dos componentes do equipamento. Quanto mais avançado é o sistema hidráulico, maiores serão as pressões de funcionamento, menores serão as folgas entre as partes móveis (carretéis de válvulas, êmbolos de pistões e bombas, etc.) e maiores serão as exigências de manutenção das características de qualidade do óleo (lubricidade e índice de viscosidade).

Num sistema lubrificante, além da lubrificação lógica entre os componentes móveis, o óleo contribui para a troca de calor e proteção quanto a corrosão das partes internas do sistema.

Óleos hidráulicos são utilizados para garantir o correto funcionamento e uma maior vida útil das máquinas que funcionam a partir de sistemas hidráulicos. A análise destes óleos, por sua vez, é um processo em que estes passam por uma avaliação laboratorial. Esta avaliação é composta por alguns testes laboratoriais, que, de forma altamente precisa, podem detetar a presença de agentes contaminantes e até mesmo o desgaste de algumas das peças das máquinas. No caso específico dos óleos hidráulicos, um dos testes mais importantes é o de contagem de partículas — que serve para avaliar o grau de contaminação por sólidos.

Além dos contaminantes sólidos, o óleo hidráulico também pode ser contaminado por combustíveis, aditivos e até mesmo água, ar e temperatura. São os ensaios envolvidos na análise que detetam essa contaminação e indicam as medidas que devem ser tomadas pelos responsáveis.

Tudo isto faz parte da manutenção preditiva, introduzida no capítulo 2.3.3, caracterizada pela monitorização periódica dos equipamentos. Esta permite prever o tempo de vida útil dessas máquinas, permitindo que as empresas façam com que seus equipamentos durem mais tempo ou se preparem para um investimento futuro.

2.4.3 Tipos de análises a óleos lubrificantes

Atualmente as empresas gastam grandes quantidades de dinheiro na substituição de componentes de máquinas que se desgastam devido ao insuficiente desempenho dos seus óleos lubrifi-

cantes.

De facto, conhecer e saber interpretar mudanças nas propriedades do óleo pode permitir aumentar o tempo de atividade e vida útil dos ativos. O desempenho e a fiabilidade de um equipamento poderão ser otimizados e problemas mitigados pela obtenção de certas informações, tais como a presença de quantidade de detritos ou partículas de peças desgastadas no óleo lubrificante (sinal de erosão e/ou contaminação).

A análise detalhada às características de óleos lubrificantes, ou outros fluidos possibilitam obter informações críticas de aviso prévio, que podem ser indicadores de falhas de uma máquina ou equipamento. Analisando e verificando uma tendência nos dados, será possível agendar a manutenção antes que possa vir a ocorrer alguma falha crítica (manutenção preventiva).

A realização de testes de rotina permitirá manter-se atualizado e informado, para gerir os riscos do equipamento e sua eficiência. Ou seja, estar sempre um passo à frente dos problemas.

De entre os diversos parâmetros a analisar no óleo, aprofundando o tópico 2.4.1 das propriedades fundamentais, destacam-se a monitorização de algumas das suas propriedades físicas, mecânicas e químicas.

- **Técnica de ICP-MS:** A determinação da presença de metais através desta técnica representa um método simples, rápido, exato e preciso para identificar e quantificar a presença de elementos (vestígios), metais de desgaste, aditivos, cloro e enxofre em matrizes de óleo.
- **Ferrografia:** Para realizar a ferrografia analítica, os resíduos sólidos suspensos num lubrificante são separados e sistematicamente depositados em uma lâmina de vidro. A lâmina é examinada sob um microscópio para distinguir os tamanhos das partículas, concentração, composição, morfologia e condição da superfície das partículas de desgaste ferroso e não ferroso. Este teste permite revelar uma condição de desgaste anormal, identificando o desgaste do componente, como este foi criado e qual a sua causa.
- **Contagem de partículas:** É o método usado para monitorizar a contaminação sólida de fluidos novos e em serviço. Cada aumento num código ISO representa uma duplicação do número de partículas nessa faixa de tamanho. Os códigos ISO para partículas $> 4 \mu\text{m}$ $> 6 \mu\text{m}$ e $> 14 \mu\text{m}$ são descritos pela norma ISO 4406.
- **Viscosidade:** No âmbito dos fluidos industriais, é um dos parâmetros mais importantes a ser avaliado, pois todo o sistema mecânico e de troca de calor é projetado para operar com a viscosidade previamente definida, que, em resumo, é a resistência que um líquido oferece ao escoamento em determinadas temperaturas. Neste ensaio também é possível detetar a presença de contaminantes, visto que estes, quando presentes no óleo, alteram as características físico-químicas originais, resultando no aumento ou diminuição da viscosidade.
- **Número total de acidez:** O ensaio de Total Acid Number (TAN) mede a acidez do fluido industrial e avalia a quantidade de reagente álcali necessária para neutralizar agentes oxidantes presentes no óleo. Além dos ensaios supracitados (de rotina), outros ensaios também

podem ser aplicados com diferentes objetivos, desde as checagens adicionais de rotina a investigações de causas raiz diretas e indiretas.

- **Contagem de partículas:** Avalia e quantifica a presença de partículas sólidas presentes no fluido. É um dos ensaios mais importantes, pois a maioria das falhas em equipamentos com óleo hidráulico ocorre devido a contaminações deste tipo. Esta contaminação pode estar relacionada a diversos fatores, como manuseio inadequado, degradação de componentes, ineficiência de filtros e até mesmo por vedações inadequadas.
- **Aparência:** Como o próprio nome indica, através de uma análise preliminar visual é possível identificar características de degradação e contaminação por outros componentes físico-químicos.
- **Concentração de água:** Todos os fluidos hidráulicos — de qualquer modelo ou fabricante — têm um limite máximo medido em ppm (partes por milhão) da concentração de água diluída, tendo em vista não comprometer as características físico-químicas necessárias para operação. A presença de água pode ocasionar a oxidação do próprio óleo e das superfícies de contacto, facilitando ações corrosivas que geram desgaste mecânico.

Análise da formação de Vernizes

Com as atuais condições de trabalho das turbinas eólicas o problema da formação de vernizes no óleo lubrificante está cada vez mais evidente. Os laboratórios estão a trabalhar arduamente em pesquisas para conhecer o mecanismo de formação de vernizes como parte das técnicas analíticas para programas de monitorização de óleo das turbinas. O desafio é ser capaz de determinar o tempo de início de formação de vernizes, já que hoje em dia não se pode determinar os compostos precursores da degradação do lubrificante mediante as técnicas de análise clássicas como TAN, RBOT e viscosidade. Observando a figura 2.10, começamos pela oxidação que é o processo inicial da formação de vernizes. Os produtos de oxidação solúveis condensam-se e polimerizam formando oligómeros (número finito de monômeros) mediante reações tipo Condensação Aldólica. Depois de algum tempo, estes oligómeros chegam ao ponto de saturação de fluido, na qual depende tanto da temperatura de trabalho como as condições de fluxo. Uma vez que se tenha alcançado o ponto de solubilidade, os contaminantes precipitam formando partículas insolúveis. Este tipo de partícula também é chamado de Contaminantes Brandos, os quais possuem um tamanho médio de aproximadamente 0,08 micros. Os contaminantes brandos são de natureza polar e atraem-se entre si. Dependendo das condições de fluxo, em certas zonas do sistema, formarão-se aglomerados de contaminantes brandos, os quais se irão depositar em diferentes partes da máquina gerando a acumulação de vernizes.

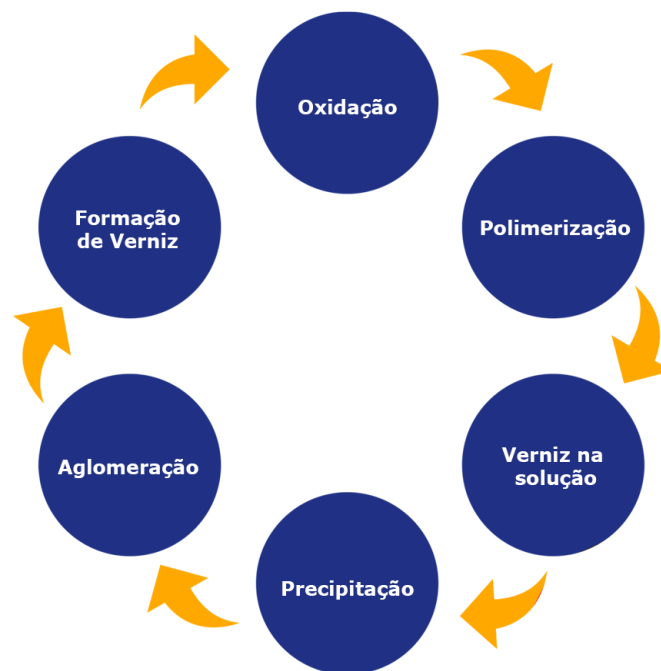


Figura 2.10: Processo formação de vernizes.

Fourier-transform infrared spectroscopy (FTIR)

A Espectroscopia por Infravermelho tornou-se recentemente uma ferramenta comum em termos de análise de óleos lubrificantes. Esta técnica é usada para quantificar compostos orgânicos moleculares, monitorizar o consumo dos aditivos (antioxidantes) e identificar compostos moleculares resultantes da degradação do óleo (oxidação). O recurso à análise por técnica de infravermelhos de óleos lubrificantes, fornece informações moleculares úteis sobre as alterações no lubrificante e no compartimento mecânico a ser lubrificado. Isto torna esta técnica numa ferramenta eficaz de triagem em ações de manutenção. Alguns parâmetros conseguem ser identificados através desta técnica, tais como: a presença de fuligem, oxidação (degradação do óleo), presença de contaminação com gasóleo, gasolina ou anticongelante.

Após a análise dos respetivos espectros e obtenção de parâmetros quantitativos monitorizados ao longo do tempo, os especialistas em lubrificação e os técnicos de manutenção, poderão tomar as decisões corretas face às necessidades de substituição do óleo.

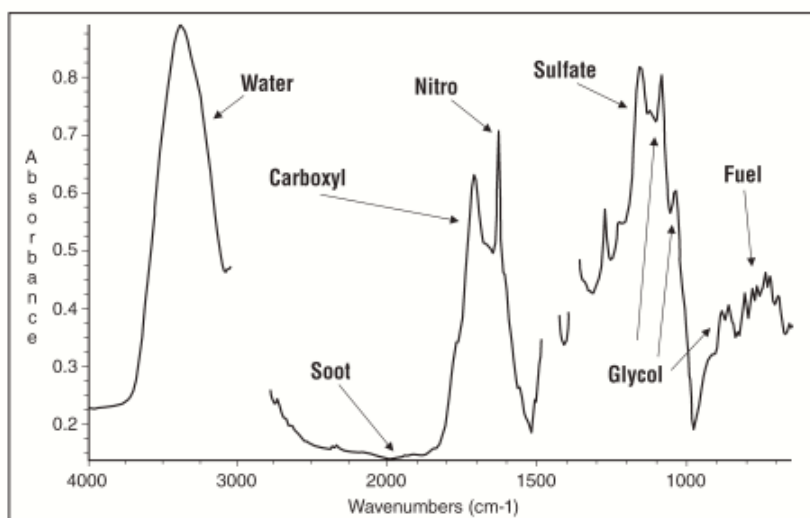


Figura 2.11: Exemplo de um Gráfico FTIR.

2.5 Inteligência Artificial

2.5.1 Introdução

O campo da Inteligência Artificial (IA) sempre despertou um fascínio no homem. Desde os primórdios que tentamos criar uma máquina que pudesse demonstrar as mesmas características que nos definem como “inteligentes”. No entanto, existem ainda diversos obstáculos a serem superados. A representação do conhecimento é um dos aspectos mais complexos para a resolução de problemas de IA e a ciência continua a procurar uma forma eficiente de representar o conhecimento de maneira mais genérica em sistemas computacionais. A IA é a ciência que procura estudar e compreender o fenômeno da inteligência e, ao mesmo tempo, um ramo da engenharia, na medida em que procura construir instrumentos para apoiar a inteligência humana. IA é o ramo da ciência da computação que se ocupa da automação do comportamento inteligente, focado no desenvolvimento de sistemas que exibem características que estão associadas à inteligência no comportamento humano, como a compreensão da linguagem, raciocínio e resolução de problemas. Independentemente da abordagem adotada, a IA trata de uma variedade de problemas cujas características são:

- Uso do computador para executar raciocínio, reconhecimento de padrões ou aprendizagem;
- Problemas que não podem ser resolvidos utilizando soluções algorítmicas tradicionais;
- Solução de problemas utilizando informação não exata, em falta ou pobremente definida;
- Respostas nem sempre exatas ou ótimas, mas suficientes em determinado contexto;
- Uso de grandes quantidades de conhecimento específico num domínio particular.

Inteligência artificial (IA), Machine Learning (ML) e Deep Learning (DL) são conceitos que estão relacionados, sendo que, habitualmente existe dificuldades para diferenciá-los. Com o obje-

tivo de ilustrar as suas diferenças, são apresentadas as seguintes definições:

- A Inteligência Artificial é o conceito mais amplo, cujo objetivo é o desenvolvimento de sistemas que exibem características que estão associadas à inteligência no comportamento humano. A Inteligência Artificial foi definida como “todos os aspetos da aprendizagem ou qualquer outra característica da inteligência que pode, em princípio, ser precisamente descrita de tal forma que uma máquina possa realizá-la”.
- O *Machine Learning* pode ser considerado como uma vertente da IA, sendo definido como “o conjunto de métodos capazes de detetar padrões automaticamente num conjunto de dados e usá-los para fazer previsões acerca de dados futuros, ou para tomar outro tipo de decisões num ambiente de incerteza”. O tema *Machine Learning* será analisado com detalhe no capítulo 2.5.2.
- O Deep Learning é um ramo do *Machine Learning* que, de uma forma simples, procura produzir representações hierárquicas de alto nível dos dados de entrada, por meio de camadas de processamento sequencial numa rede neuronal artificial.

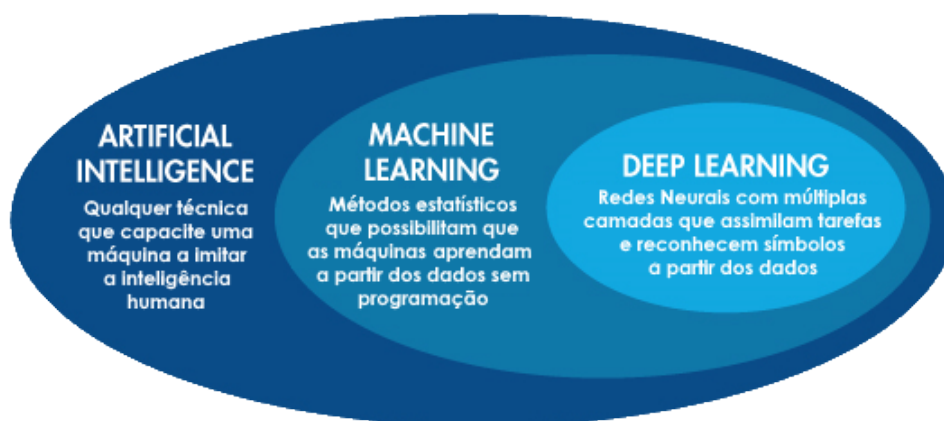


Figura 2.12: Diferenças entre IA, ML e DL.

2.5.2 Conceitos de *Machine Learning*

Na maioria dos casos, quando se deseja resolver um problema com o auxílio de um computador, é necessário um algoritmo. Um algoritmo consiste na programação de uma dada sequência de instruções com as quais é possível transformar uma entrada numa saída desejada. O *Machine Learning* pode ser definido como “o campo de estudo que dá ao computador a habilidade de aprender sem ser explicitamente programado”. De forma mais simples, pode dizer-se que “os algoritmos de *Machine Learning* usam métodos computacionais para aprender informação diretamente dos dados sem recurso a equações pré-definidas como modelo”.

O *Machine Learning* certamente não será capaz de resolver todos os problemas para os quais ainda não há resposta, no entanto, o seu potencial não deve ser desprezado. De entre as várias tarefas para as quais há uma elevada probabilidade das ferramentas de *Machine Learning* serem usadas com sucesso, destacam-se:

-
1. Procurar soluções para problemas complexos para os quais as abordagens tradicionais não encontraram nenhuma ou, tendo encontrado, requeiram demasiadas afinações de parâmetros ou uma longa lista de regras.
 2. Auxiliar o ganho de “intuições” acerca de grandes quantidades de dados. No caso da manutenção, o *Machine Learning* permite integrar informação e aproveitar o potencial da grande quantidade de dados que, tipicamente, são armazenados.

Os modelos preditivos possuem a capacidade de aprender padrões a partir de dados históricos e assim prever resultados futuros, com uma determinada probabilidade associada, com base nestes padrões observados. A precisão preditiva de um modelo depende da relevância, quantidade e qualidade dos dados.

Tipos de *Machine Learning*

Os sistemas de *Machine Learning* podem dividir-se em várias categorias, de acordo com vários aspetos:

1. Se são ou não treinados com supervisão:
 - (a) Supervised learning
 - (b) Unsupervised learning
 - (c) Reinforcement learning
 - (d) Semisupervised learning
2. Se podem aprender de forma incremental:
 - (a) Batch learning
 - (b) Online learning
3. Se fazem previsões comparando os novos dados com pontos conhecidos ou se constroem novos modelos preditivos:
 - (a) Instance-based learning
 - (b) Model-based learning

Supervised, unsupervised, reinforcement learning e Semisupervised learning

Os sistemas de *Machine Learning* podem ser divididos de acordo com a quantidade e tipo de supervisão que recebem durante a fase de treino. Este aspeto permite a divisão dos modelos *Machine Learning* em três categorias principais (supervised, unsupervised e reinforcement learning) e, ainda, numa quarta categoria que consiste simplesmente na combinação de modelos das categorias anteriores (semisupervised learning).

Supervised learning

Supervised learning é um dos modos de aprendizagem mais comum e também com maior sucesso. Neste, os dados fornecidos aos algoritmos durante a fase de treino incluem a solução desejada (label), isto é, a variável dependente resultante das variáveis independentes observadas. É assim possível desenvolver modelos preditivos capazes de gerar respostas para novos dados.

Como observamos na figura 2.13 existem dois principais tipos de problemas de supervised learning: classificação e regressão.

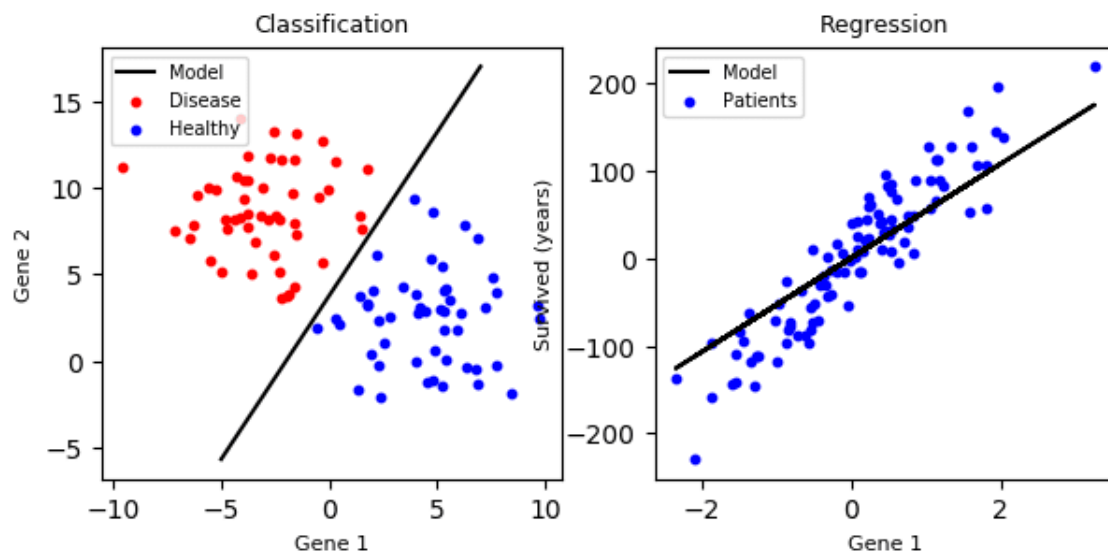


Figura 2.13: Exemplos de supervised learning.

As técnicas de classificação são utilizadas para prever a resposta, isto é, a classificação (class label), a partir de um conjunto de valores de entrada. As respostas são discretas (os modelos classificam os dados em categorias). Os problemas de classificação podem ainda ser separados em: classificação binária (binary classification), que consiste na distinção entre duas classes, e problemas de classificação multi-classe (multiclass classification), quando o número de classes é superior a dois. Classificar um e-mail como spam ou não spam é um exemplo de um problema típico de binary classification enquanto que, prever qual a língua de um website com base no texto é um exemplo de um problema de multiclass classification, onde, neste caso, as classes seriam uma lista predefinida de possíveis línguas. Por outro lado, as técnicas de regressão preveem respostas contínuas. Um exemplo de um problema deste tipo é, dado um conjunto de dados sobre o tamanho de casas no mercado imobiliário, tentar prever o seu preço (variável contínua). As variáveis utilizadas em modelos de *Machine Learning* que contêm informação relevante acerca do problema e permitem ao modelo aprender com sucesso são denominadas por features (ou atributos). Uma feature pode ser diretamente medida, calculada a partir dos sinais medidos ou, simplesmente, gerada pelo programador (por exemplo, a identificação de um equipamento). Os algoritmos mais populares de supervised learning são: k-nearest neighbors (kNN), linear regression, logistic regression, support vector machines (SVMs), decision trees, random forests, naive Bayes e neural networks.

Unsupervised learning

Em alguns casos, conseguir dados com a solução desejada (label) pode ser caro ou até mesmo impossível. Em unsupervised learning um algoritmo procura aprender padrões e relações existentes num conjunto de dados sem categorização (sem labels) fornecidos. Os sistemas de unsupervised learning procuram encontrar padrões escondidos e estruturas intrínsecas nos dados.

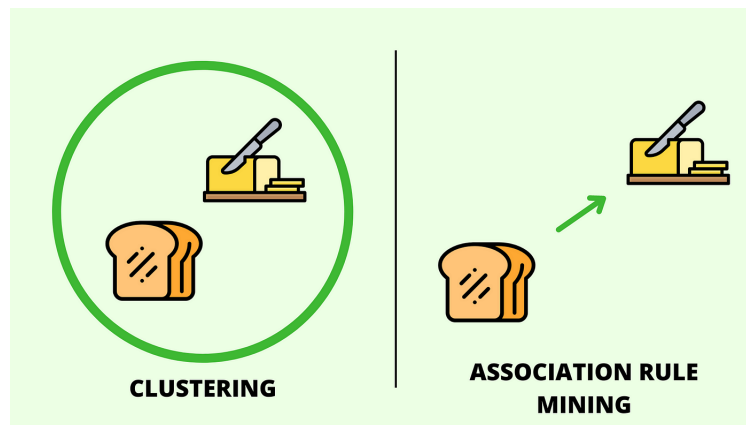


Figura 2.14: Diferença entre Clustering e Association Rule Mining.




Figura 2.15: Anomaly Detection.

Dentro do unsupervised learning destacam-se quatro principais tarefas: clustering, que consiste na divisão dos dados em grupos (clusters) semelhantes; visualização e redução de dimensionalidade, que procura simplificar os dados sem perda significativa de informação; deteção de anomalias, uma vez que o sistema é treinado com exemplos reais, perante um novo ponto é capaz de determinar se este se encontra fora do normal; association rule learning, que consiste em encontrar relações entre features.

Reinforcement learning

Em reinforcement learning, o sistema tenta aprender qual a melhor ação a ser tomada, dependendo das circunstâncias na qual essa ação será executada. Como, a priori, não sabe o que irá acontecer no futuro, é desejável uma abordagem que leve em consideração essa incerteza, capaz de incorporar as eventuais mudanças no processo de tomada da melhor decisão. Uma recompensa ou punição é dada ao sistema de aprendizagem, dependendo da decisão tomada; ao longo do tempo e com a repetição do processo, espera-se que este seja capaz de associar as ações que geram maior recompensa para cada situação que o ambiente apresenta, e passe a evitar as ações que geram punição ou recompensa menor.

Semisupervised learning

Alguns algoritmos são capazes de lidar, em simultâneo, com uma combinação de dados de treino categorizados (normalmente em pequena quantidade) e não categorizados (em grande quantidade). Esta combinação de um grande número de dados não categorizados, regra geral mais fáceis de obter, com alguns dados categorizados, geralmente dispendiosos de obter, pode levar a um aumento da performance do sistema de aprendizagem.

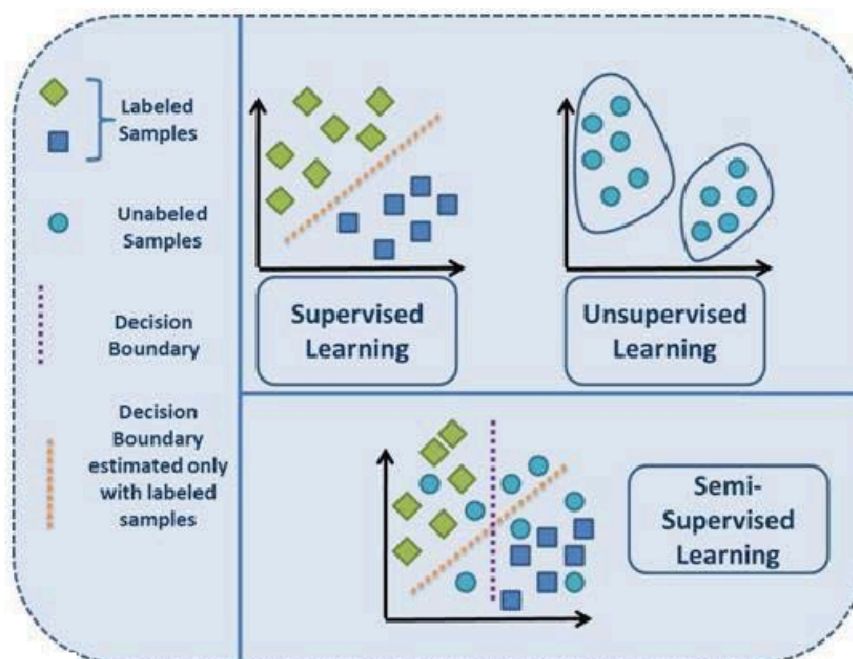


Figura 2.16: Semi-Supervised Learning

Batch e online learning

Outro critério usado para classificar os sistemas de *Machine Learning* é a sua capacidade de aprender de forma incremental, a partir de um fluxo de dados recebidos. Em batch learning, (figura 2.17 (a)), o sistema é incapaz de aprender incrementalmente, sendo que necessita de acesso à totalidade dos dados para ser treinado. De modo a fornecer novos dados ao sistema, é necessário

treinar um nova versão com o conjunto de dados completo (não apenas os novos dados, mas também os antigos). Por outro lado, em online learning, figura 2.17 (b), a fase de treino é realizada de forma incremental, isto é, o sistema é capaz de treinar continuamente ao ser alimentado com exemplos. Este modo de treino é ideal para sistemas que recebem um fluxo de dados contínuo e necessitam de se adaptar de forma rápida ou autónoma.

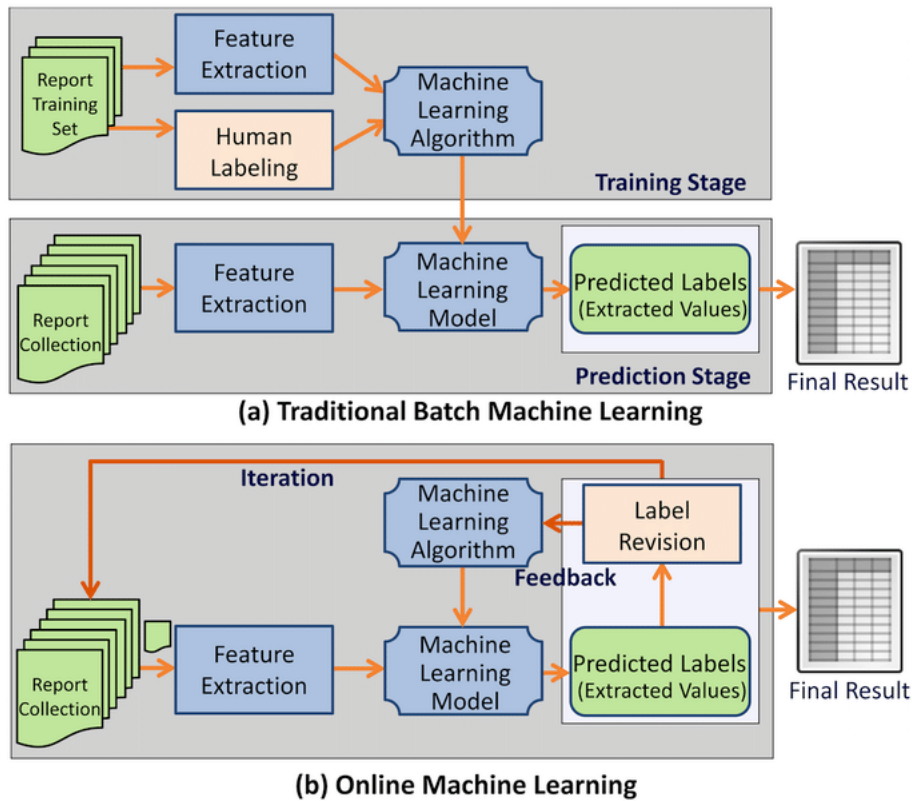


Figura 2.17: Batch e Online Learning

Instance-based e model-based learning

A última divisão dos sistemas de *Machine Learning* baseia-se no modo como as previsões são efetuadas, ou seja, na forma como os modelos generalizam. Dado um conjunto de exemplos para treino, o modelo tem de ser capaz de generalizar para exemplos desconhecidos. Esta generalização pode basear-se em medidas de similaridade (distância) aos exemplos conhecidos: instance-based learning, ou então pode basear-se num modelo matemático associado a estes sistemas: model-based learning.

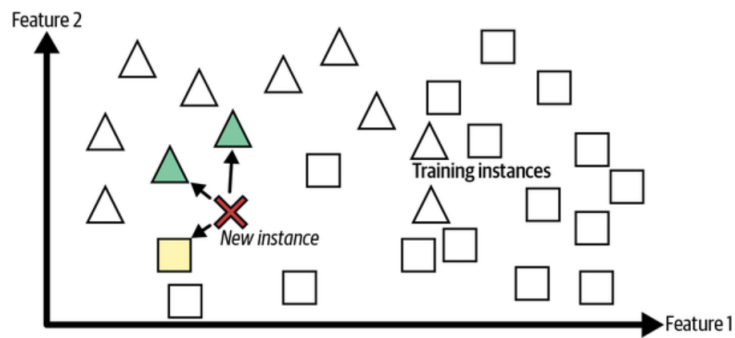


Figura 2.18: Instance based learning




Figura 2.19: Model based learning

Artificial Neural Networks

As Artificial Neural Networks (ANN), ou Redes Neurais Artificiais, são um conjunto de técnicas computacionais que representam um modelo matemático inspirado no sistema nervoso central, em particular o cérebro. As Artificial Neural Networks são modeladas de forma análoga ao cérebro humano, sendo compostas por vários neurónios artificiais (o número de neurónios e de conexões entre estes é, no entanto, significativamente menor do que o cérebro humano). Na Figura 2.20 está representada uma Artificial Neural Networks com 4 camadas: camada de entrada, duas camadas intermédias e camada de saída.




Figura 2.20: Rede neuronal com 4 camadas.

As redes neuronais artificiais têm sido aplicadas com sucesso nas mais diversas áreas, sendo que, a sua utilização tem vindo a aumentar progressivamente, uma vez que um número cada vez maior de problemas mostra-se adequado à resolução através desta técnica e as soluções obtidas apresentam um melhor desempenho quando comparadas com outros algoritmos.

Planeamento de um projeto de *Machine Learning*

No presente projeto será seguido o *workflow* apresentado na figura 2.21. Um projeto de *Machine Learning* deve começar, sempre, pelo estabelecimento rigoroso e claro dos objetivos, uma vez que um sistema de *Machine Learning* cumpre uma tarefa muito específica e a definição de objetivos muito vagos pode levar a que o que o modelo desenvolvido não seja capaz de prever exatamente o que se pretende. Muito possivelmente, a parte mais importante de um projeto de *Machine Learning* é a capacidade de entender os dados utilizados e como estes se relacionam com a tarefa que desejamos resolver. Não será eficaz escolher aleatoriamente um algoritmo, usar o conjunto de dados que temos disponível e esperar bons resultados. É necessário entender o que está a acontecer no conjunto de dados antes de começar a construir um modelo. Quando construirmos uma solução de *Machine Learning* devemos responder ou pelo menos ter em mente as seguintes questões:

- A que perguntas estamos a tentar responder? O conjunto de dados disponível permite responder a estas perguntas?
- Qual a melhor forma de parafrasear a minha questão como um problema de *Machine Learning*?
- O conjunto de dados disponível é suficiente para representar o problema que estamos a tentar resolver?
- Que *features* (ou atributos) foram extraídos e serão estes capazes de conduzir às corretas previsões?

- Como medir o sucesso da aplicação de *Machine Learning*?
- Como irá a solução de *Machine Learning* interagir com o resto do processo?

Os algoritmos e métodos de *Machine Learning* são apenas uma parte de um processo maior para resolver um problema específico, e é importante manter um panorama geral em mente. Por vezes, muito tempo é despendido a construir soluções complexas de *Machine Learning*, apenas para descobrir no final que elas não resolvem o problema que estaríamos à espera. Ao aprofundar os aspetos técnicos do *Machine Learning*, é fácil perder de vista os objetivos finais. É importante manter em mente todas as suposições criadas, de forma explícita ou implícita, quando são construídos modelos de *Machine Learning*.

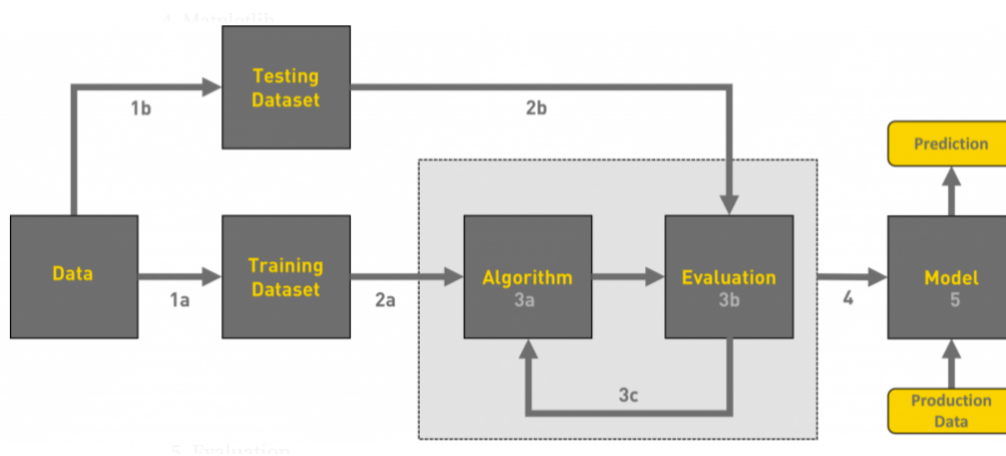


Figura 2.21: Proposta de *workflow* de um projeto de *Machine Learning*.

1. **Recolha de dados**
2. **Pré-processamento dos dados**
3. **Pesquisa do modelo mais adequado**
4. **Treinar e testar o modelo**
5. **Avaliar**

Recolha de dados

O processo de recolha de dados depende do tipo de projecto que pretendemos realizar. Se quisermos realizar um projecto de ML que utilize dados em tempo real, podemos criar um sistema IoT que utilize dados de diferentes sensores. O conjunto de dados pode ser recolhido de várias fontes, como um ficheiro, uma base de dados, um sensor e muitas outras fontes, mas os dados recolhidos não podem ser utilizados diretamente para realizar o processo de análise, uma vez que podem existir muitos dados em falta, valores extremamente grandes, dados de texto não organizados ou dados com ruído. Por conseguinte, para resolver este problema, é efetuada a preparação dos dados.

Pré-processamento dos dados

O pré-processamento de dados é uma das etapas mais importantes da aprendizagem automática. É o passo mais importante que ajuda a construir modelos com maior precisão. Na aprendizagem automática, existe uma regra 80/20. Todos os cientistas de dados devem dedicar 80% do tempo ao pré-processamento de dados e 20% ao desempenho efetivo da análise.

O pré-processamento de dados é um processo de limpeza dos dados em bruto, ou seja, os dados são recolhidos no mundo real e convertidos num conjunto de dados limpos. Por outras palavras, sempre que os dados são recolhidos de diferentes fontes, são recolhidos em formato bruto e não são viáveis para a análise. Por conseguinte, são executadas determinadas etapas para convertê-los num pequeno conjunto de dados limpos, sendo esta parte do processo designada por pré-processamento de dados.

Como sabemos, o pré-processamento de dados é um processo que consiste em transformar os dados brutos em dados limpos, de modo a poderem ser utilizados para treinar o modelo. Assim, precisamos definitivamente de pré-processamento de dados para obter bons resultados do modelo aplicado em projectos de aprendizagem automática e aprendizagem profunda.

A maioria dos dados do mundo real é confusa, alguns desses tipos são:

1. **Dados em falta:** Os dados em falta podem ser encontrados quando não são criados continuamente ou devido a problemas técnicos na aplicação (sistemas IOT).
2. **Dados com "ruído":** Este tipo de dados é também designado por outliers, o que pode ocorrer devido a erros humanos (recolha manual dos dados) ou a algum problema técnico do dispositivo no momento da recolha dos dados.
3. **Dados inconsistentes:** Este tipo de problema ocorre devido a erros humanos (erros no nome ou nos valores) ou à duplicação de dados.

Três tipos de dados:

1. Numérico
2. Categórico
3. Ordinal

Algumas das técnicas básicas de pré-processamento que podem ser utilizadas para converter dados em bruto são:

1. **Conversão dos dados:** Os modelos de aprendizagem automática só podem tratar características numéricas, os dados categóricos e ordinais devem ser convertidos de alguma forma em características numéricas.
2. **Ignorar os valores em falta:** Sempre que encontrarmos dados em falta no conjunto, podemos remover a linha ou a coluna correspondente, consoante as nossas necessidades. Este

método é conhecido por ser eficiente, mas não deve ser efectuado se houver muitos valores em falta no conjunto de dados.

3. **Preenchimento dos valores em falta:** Sempre que encontrarmos dados em falta no conjunto de dados, podemos preencher os dados em falta manualmente, sendo normalmente utilizados a média, a mediana ou o valor de frequência mais elevado.
4. **Aprendizagem automática:** Se houver dados em falta, podemos prever quais os dados que devem estar presentes na posição vazia, utilizando os dados existentes.
5. **Deteção de valores anómalos:** Há alguns dados de erro que podem estar presentes no nosso conjunto de dados e que se desviam drasticamente de outras observações num conjunto de dados. [Exemplo: peso humano = 800 kg; devido a um erro de digitação de 0 extra].

Feature Engineering

Uma *feature* é um atributo preditivo para o modelo. O objetivo do *feature engineering* é procurar aumentar o poder preditivo dos algoritmos de *Machine Learning*, criando novas *features* a partir dos dados disponíveis. Regra geral, o *feature engineering* é realizado em primeiro lugar sendo que, de seguida, ocorre a seleção de *features*, eliminando *features* irrelevantes, redundantes ou com alta correlação. Tendo como ponto de partida as diferentes fontes de informação apresentadas na secção anterior, será criado um único *dataset*, que será usado para a aplicação dos modelos preditivos.

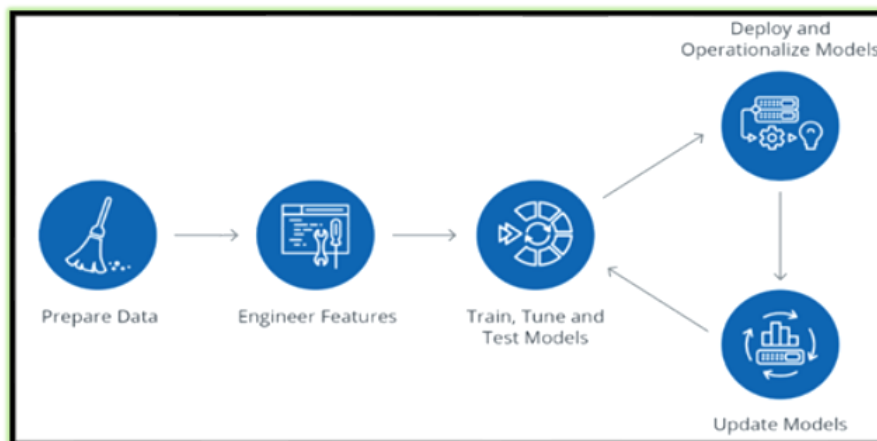


Figura 2.22: Exemplo de *feature engineering*.

Pesquisa do modelo mais adequado

O nosso principal objetivo é desenvolver o modelo com o melhor desempenho possível, utilizando os dados pré-processados e escolhendo a melhor técnica, das mencionadas no capítulo 2.5.2.

Treinar e testar o modelo

Para treinar um modelo, dividimos inicialmente o modelo em três secções: "Dados de treino", "Dados de validação" e "Dados de teste".

Treina-se o modelo utilizando o "conjunto de dados de treino", afinam-se os parâmetros utilizando o "conjunto de validação" e, em seguida, testa-se o desempenho do modelo num "conjunto de dados de teste" inédito. Um aspeto importante a ter em conta é que, durante a formação do modelo, apenas está disponível o conjunto de formação e/ou validação. O conjunto de dados de teste não deve ser utilizado durante a formação do modelo. O conjunto de teste só estará disponível durante o teste do modelo.

Um problema comum neste fase é, ao afinar os hiperparâmetros de modo a procurar diminuir o erro de generalização no conjunto de teste, a performance do modelo para novos dados pode piorar. Ora, ao realizar uma segunda divisão do conjunto de treino em dois subconjuntos: subconjunto de treino e subconjunto de desenvolvimento, é possível resolver este problema. A esta técnica de validação dá-se o nome de *Holdout*. O processo de treino dos algoritmos é realizado no subconjunto de treino e o novo subconjunto de desenvolvimento fornece uma avaliação imparcial do ajuste do modelo aos dados de treino permitindo simultaneamente afinar o modelo e hiperparâmetros de modo a procurar uma melhor performance. Por fim, o conjunto de teste é utilizado para obter uma estimativa do erro de generalização para o modelo. Caso fosse apenas considerada a avaliação feita sobre o subconjunto de desenvolvimento corria-se o risco de se lançar um sistema com uma performance inferior à esperada, uma vez que os hiperparâmetros são afinados para melhorar as métricas de avaliação nesse subconjunto. O conjunto de teste contém dados que o modelo nunca "viu" anteriormente, permitindo assim simular o comportamento do modelo com dados futuros. Esta avaliação poderá ser generalizada para o desempenho operacional do modelo.




Figura 2.23: Repartição ideal de um conjunto de dados

1. **Conjunto de treino:** O conjunto de treino é o material através do qual o computador aprende a processar a informação. A aprendizagem automática utiliza algoritmos para efetuar a parte de formação. Um conjunto de dados utilizado para a aprendizagem, ou seja, para ajustar os parâmetros do classificador.
2. **Conjunto de validação:** A validação é utilizada principalmente na aprendizagem automá-

tica aplicada para estimar a capacidade de um modelo de aprendizagem automática em dados não vistos. Um conjunto de dados não vistos é utilizado a partir dos dados de treino para ajustar os parâmetros de um classificador.

3. **Conjunto de teste:** Um conjunto de dados nunca vistos utilizado apenas para avaliar o desempenho de um modelo.

Avaliar

A única forma de determinar a capacidade do modelo em generalizar para novos casos é mesmo testá-lo com casos nunca antes vistos. Para isso, regra geral, o *dataset* é dividido em dois conjuntos: o conjunto de treino e o conjunto de teste. Como o próprio nome indica, o conjunto de treino será utilizado para treinar o modelo. Durante esta fase de treino, o modelo não tem acesso aos dados atribuídos ao conjunto de teste. Ao avaliar o modelo no conjunto de teste, é possível obter uma estimativa da taxa de erro em novos casos, chamada de erro de generalização. Este valor permite perceber a *performance* do modelo em novos registos desconhecidos. Caso o erro cometido pelo modelo seja baixo no conjunto de treino mas alto no conjunto de teste significa que o modelo pode apresentar *overfitting*, isto é, o modelo é capaz de explicar muito bem os dados de treino, mas não de generalizar. Por outro lado, o *underfitting* acontece quando o modelo "não aprendeu o suficiente", ou seja, não é capaz de capturar a tendência subjacente dos dados de treino. Na Figura 2.24 estão representados estes comportamentos. Dependendo do modelo em questão, é importante procurar um desempenho que se situe entre o *underfitting* e o *overfitting*. Estes dois termos estão também ligados aos conceitos de *bias* e *variance*. O conceito de *bias* está relacionado com o *underfitting* e significa que o algoritmo tende a aprender consistentemente a mesma coisa errada. O conceito de *variance*, relacionado com o *overfitting*, ocorre quando não existe um padrão nos erros de previsão.




Figura 2.24: Diferença de *underfitting* e *overfitting*

Cada algoritmo de *Machine Learning* possui diversos parâmetros que podem ser afinados de modo a procurar obter uma melhor performance para cada dataset específico. A estes parâmetros intrínsecos dos algoritmos dá-se o nome de hiperparâmetros.

Otimização dos hiperparâmetros

Os hiperparâmetros desempenham um papel fundamental no treino e desempenho das redes neuronais. Eles são responsáveis por determinar a arquitetura e o comportamento da rede, influenciando diretamente na sua capacidade de aprendizagem e generalização. A escolha adequada dos hiperparâmetros é crucial para obter um bom desempenho da rede neuronal num determinado problema.

Por exemplo, o número de camadas e neurónios por camada afetam a capacidade da rede em aprender representações complexas e extrair características relevantes dos dados. Uma rede com muitas camadas ou neurónios em excesso pode levar a um sobreajuste (*over fitting*), onde a rede memoriza os dados de treino em vez de aprender padrões generalizáveis. Por outro lado, uma rede com poucas camadas ou neurónios pode ter uma capacidade limitada para capturar a complexidade dos dados. Além disso, a escolha da função de ativação afeta a não-linearidade da rede e a sua capacidade de aproximar funções complexas. Funções de ativação populares, como a função ReLU (*Rectified Linear Unit*) e a função sigmoide, têm características diferentes e podem ser mais adequadas para diferentes tipos de problemas. A taxa de aprendizagem é outro hiperparâmetro crítico que determina o tamanho da decisão durante o processo de otimização. Uma taxa de aprendizagem muito alta pode resultar em oscilações e dificuldade de convergência, enquanto uma taxa de aprendizagem muito baixa pode levar a uma convergência lenta ou estagnação em mínimos locais. A função de custo usada para avaliar o desempenho da rede também é um hiperparâmetro importante. Diferentes funções de custo são adequadas para diferentes tipos de problemas e podem afetar a maneira como a rede aprende e se adapta aos dados. Além destes exemplos, existem outros hiperparâmetros, como o tamanho do lote (*batch size*), o número de épocas, a regularização, entre outros, que podem influenciar o treino e a capacidade de generalização da rede neural.

A escolha apropriada dos hiperparâmetros é um desafio e geralmente requer testes e ajustes iterativos. Portanto, compreender e otimizar os hiperparâmetros é uma parte fundamental do processo de treino das redes neuronais e pode ter um impacto significativo no desempenho e na capacidade de generalização da rede.

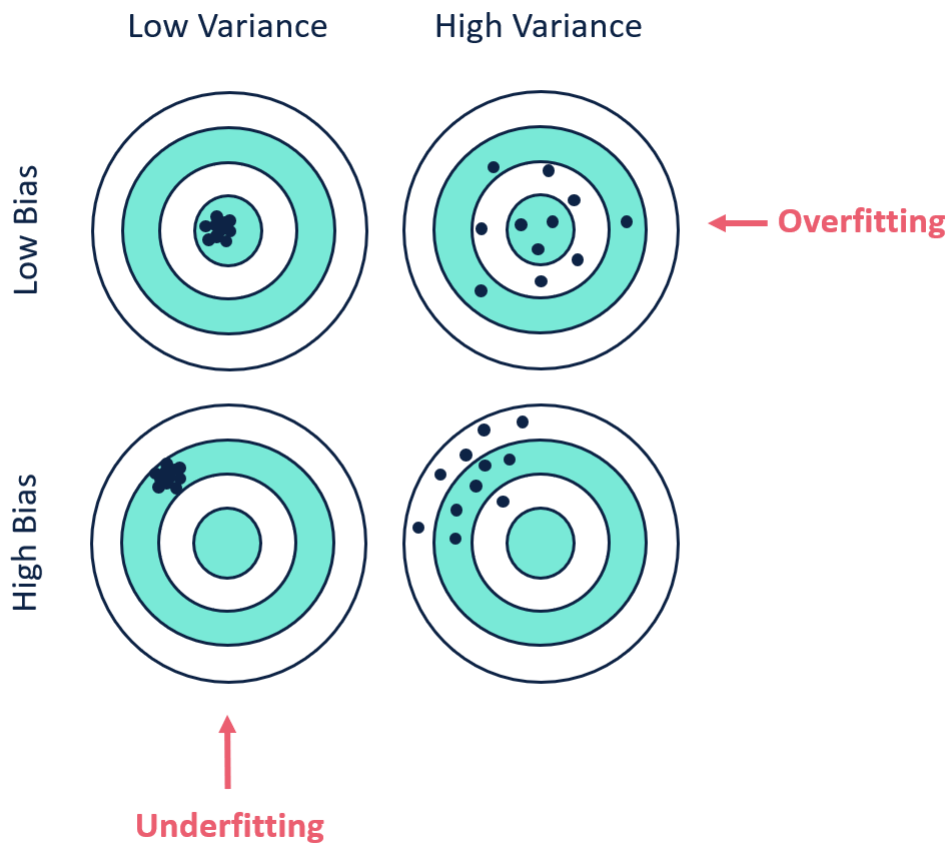


Figura 2.25: Diferença de *bias* e *variance*

O processo de avaliação dos modelos é essencial em qualquer projeto de *Machine Learning*. Existem várias métricas de avaliação distintas, sendo que, é necessário escolher com cuidado quais usar, uma vez que a performance dos modelos será inteiramente dependente da métrica escolhida. A métrica mais simples é a *Accuracy*, que representa a razão entre o número de previsões efetuadas com sucesso e o número total de previsões efetuadas. No entanto, quando existe desequilíbrio entre classes, esta métrica pode não ser a mais indicada.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (2.5)$$

A matriz de confusão (*Confusion Matrix*) - permite determinar como o modelo se comporta na previsão de cada categoria. Regra geral, cada linha da matriz de confusão representa a categoria real, enquanto que as colunas representam as categorias previstas pelo modelo.

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Figura 2.26: Matriz de Confusão para um problema de classificação binária

Na primeira linha da figura 2.26 são representados os verdadeiros-positivos (True Positive - TP) e os falsos-negativos (False Negative - FN) e na segunda linha são representados os falsos-positivos (False Positive - FP) e os verdadeiros-negativos (True Negative - TN). No entanto, ao avaliar modelos de *Machine Learning* é conveniente utilizar métricas mais concisas, baseadas na matriz de confusão: *Precision* e *Recall*.

A *Precision* representa a razão entre o número de verdadeiros-positivos e a soma de verdadeiros-positivos com falsos-positivos, medindo assim a percentagem de previsões positivas que o são realmente.

$$Precision = \frac{TP}{TP + FP} \quad (2.6)$$

O *Recall* define-se como a razão entre o número de verdadeiros-positivos e a soma de verdadeiros-positivos com falsos negativos e representa a capacidade do modelo em detetar os exemplos positivos.

$$Recall = \frac{TP}{TP + FN} \quad (2.7)$$

Contudo, as métricas *Precision* e *Recall* não são independentes: o aumento de uma implica a diminuição da outra.

O F_1 score é uma média harmónica destas duas métricas que dá mais peso a valores mais baixos, pelo que um modelo com um elevado F_1 score tem *Precision* e *Recall* elevados.

$$F_1 score = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} = 2 \times \frac{Precision \times Recall}{Precision + Recall} = \frac{2TP}{TP + FN + FP} \quad (2.8)$$

Estas métricas são, regra geral, mais importantes para problemas de classificação binária,

no entanto, permitem também tirar conclusões importantes em problemas de classificação multi-classe.

A *Accuracy*, para classificação multi-classe, define-se como a fração de exemplos corretamente classificados. Uma vez mais, quando existe um desequilíbrio entre classes, a *Accuracy* pode não ser a métrica de avaliação mais adequada. Em relação às métricas *Precision*, *Recall* e F_1 score para problemas multi-classe, estas são calculadas, para cada uma das classes, de forma semelhante aos problemas binários, obtendo assim, para cada uma das classes, um valor de *Precision*, *Recall* e F_1 score. De seguida, é possível realizar uma média sob todas as classes. Esta média pode ser realizada de acordo com uma das seguintes estratégias:

- **“Macro Averaging”**: É realizada uma média não ponderada com igual peso para todas as classes, independentemente do seu tamanho relativo;
- **“Weighted Averaging”**: É realizada uma média ponderada tendo em consideração o tamanho relativo de cada classe;
- **“Micro Averaging”**: É calculado o número total de falsos positivos, falsos negativos e verdadeiros positivos em todas as classes e, de seguida, utilizando estes valores, as métricas de avaliação multi-classe são calculadas.

2.6 Indústria e Inteligência Artificial

Na sociedade atual, a informação e o conhecimento têm um papel crescente na criação de riqueza, de bem-estar e melhoria da qualidade de vida das pessoas. A revolução digital está a conduzir a mudanças profundas nos hábitos de consumo dos clientes, devido a, entre outros fatores, um maior acesso a dados e a um crescente desenvolvimento de novas tecnologias. Uma alavanca fundamental para a transformação dos modelos de negócio é a *Data Science*, que se baseia no uso combinado de técnicas de Inteligência Artificial, *Machine Learning*, matemática, estatística e bases de dados. A crescente utilização destas técnicas é impulsionada por diversos fatores: um aumento sem precedentes do volume e da tipologia dos dados disponíveis; a conectividade e o acesso a estes dados; a melhoria dos algoritmos utilizados e ainda o aumento da capacidade computacional dos sistemas.

As tecnologias de IoT irão desempenhar um papel fundamental na transição da área da manutenção de uma empresa para a filosofia da Indústria 4.0, baseada na sensorização de ativos físicos, assim capazes de gerar informações associadas ao seu funcionamento. A implementação de sensores nos equipamentos e a análise e armazenamento da informação produzida relativa ao seu funcionamento permite uma movimentação no sentido de uma manutenção preditiva e prescritiva, já que possibilita a utilização das informações recolhidas e de métodos de IA para estudar e prever o comportamento dos equipamentos. A análise de dados permite igualmente a deteção de anomalias e, por outro lado, encontrar padrões e condições de funcionamento ótimas ou de maior eficiência ou prever tendências de necessidades futuras e planear as operações de uma linha de produção de forma otimizada. A transformação de uma indústria tem ser um processo contínuo e

abrangente, que além da melhoria de tecnologias, deve igualmente afetar toda a cadeia envolvente e sequencial de processos, modelos de negócio, aspetos organizacionais e de gestão, criando por sua vez desafios significativos para as empresas. Alguns dos desafios mais relevantes são a pouca familiarização com uma visão e estratégia digital, desconhecimento dos benefícios tecnológicos, recursos financeiros, segurança de dados, falta de qualificação de recursos humanos, falta de normas e legislação, ou insuficiências na infraestrutura tecnológica. A criação de uma arquitetura integrativa de conectividade entre equipamentos para eficazmente gerir a recolha, armazenamento e processamento dos dados é essencial para tornar estes acessíveis e visualizáveis, possibilitando a análise e utilização de dados para promover operações mais eficientes, com aplicação de diversas técnicas baseadas em Inteligência Artificial.

No entanto, na área da manutenção, é importante perceber o motivo subjacente que leva um sistema de IA a recomendar uma determinada ação. Um dos benefícios de aumentar a explicabilidade dos sistemas de IA é um aumento da confiança no sistema. Se o utilizador for capaz de entender o que levou a uma determinada recomendação gerada pela IA, o nível de confiança nessa decisão é superior.

Capítulo 3

Aplicação de modelos de Machine learning e Resultados

Na prática, a implementação da manutenção preditiva com recurso a inteligência artificial, utilizando algoritmos de *machine learning*, envolve um conjunto de etapas que foram abordadas teoricamente no capítulo 2 desta dissertação. Nesta secção, irá ser explorada a aplicação dos conceitos e técnicas discutidos, com o objetivo de demonstrar os resultados da análise de dados de turbinas eólicas com recurso a *machine learning*.

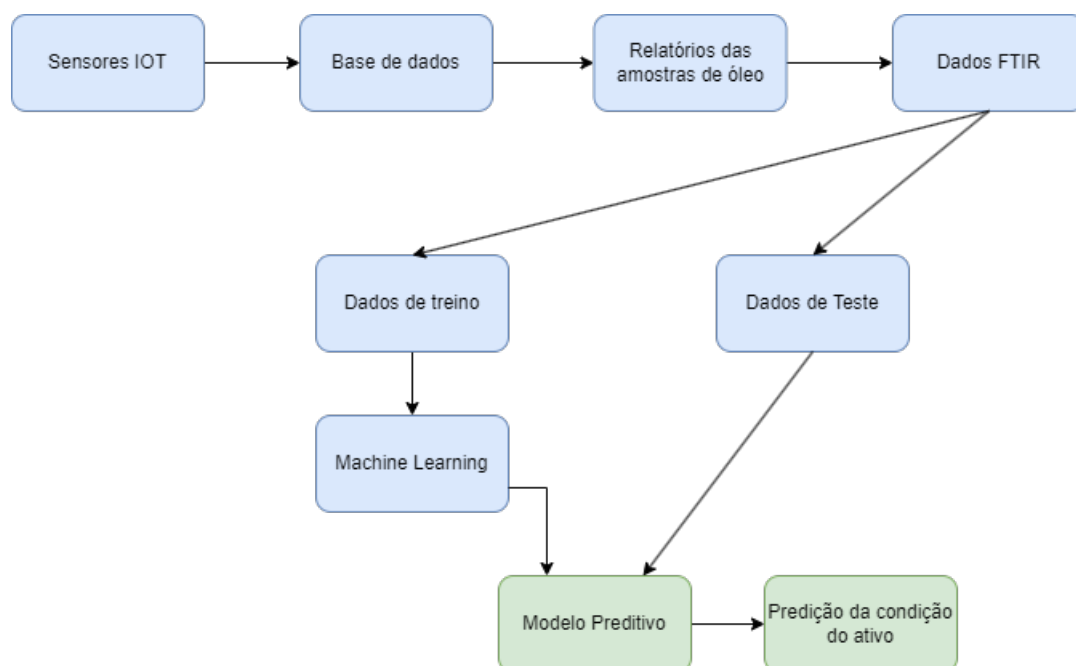


Figura 3.1: Arquitetura do sistema.

3.1 Origem dos dados

Os dados utilizados neste trabalho foram obtidos a partir de uma base de dados fornecida pela Vestas, intitulada de: "*Vestas Lubrification Management*", com o objetivo de dar diagnósticos avançados dos equipamentos, permitir a prevenção de falhas atempadamente, mitigando a sua ocorrência ao máximo e minimizar custos. A base de dados contem amostras de óleo em bom estado, mau estado e em perigo, coletadas e analisadas diariamente de turbinas Vestas.

Cada amostra é submetida a testes laboratoriais, que destes resulta um relatório com várias informações, destacando para este trabalho o estado da amostra, horas de funcionamento do equipamento e gráficos FTIR. De todas as amostras da plataforma, a pedido da equipa de manutenção, foram selecionadas amostras apenas da caixa de velocidades com o lubrificante: Castrol Optigear Synthetic CT 320. O foco nos dados FTIR foi devido a não existir ainda ferramentas na empresa, que permitissem extrair informações deste tipo de dados.

Depois de selecionar e descarregar a amostra da plataforma, começa-se por fazer algumas alterações ao ficheiro base, tais como transpor os dados (para colocar cada amostra por linha), substituir as Vírgulas por pontos, adicionar as horas de uso do lubrificante correspondente e a classificação da amostra. Esta estrutura corresponde aos dados de treino, que a figura 3.2 demonstra um exemplo dos mesmos. A diferença, relativamente aos dados de verificação, consiste na eliminação da última coluna (*target*).

EBQ	EBR	EBS	EBT	EBU
552	551	550	horasuso	target
90.692764	91.07328	91.46327	37227	1
90.45412	90.4492	90.55723	10581	0
90.24783	90.101684	89.78419	7726	0
89.55807	89.45985	89.299835	3580	0
91.79639	91.61929	91.40914	42284	1
92.46266	92.29573	92.161804	37125	1
88.56974	88.12464	87.72857	31654	1

Figura 3.2: Exemplo do ficheiro dos dados de treino.

Coluna	Descrição	Tipo de característica
[4000-550] ¹	Concentração do espectro medido	Numérica
horasuso ²	Horas de uso do lubrificante correspondente á amostra	Numérica
target ³	Diagnóstico do laboratório (1 = Com problemas; 0 = Sem Problemas)	Categórica

Tabela 3.1: Descrição de cada característica.

1. A base de dados permite extrair os coeficientes da transformada de *Fourier* do gráfico FTIR num ficheiro .csv, para estes serem lidos pelo modelo. Cada uma das amostras teve de ser

transposta, para estarem representadas por linhas. As primeiros 3450 colunas representam o espectro medido [4000-550]cm-1.

2. O registo de manutenção, que contém a informação relacionada com a substituição de componentes, permite gerar novas *features* potencialmente importantes, como, as horas de uso do lubrificante da amostra (horasuso). É de esperar que esta *feature* se relacione bem com as possíveis falhas dos componentes, dado que, quanto maior o tempo de utilização de um componente, maior será a degradação do óleo esperada. É relevante notar que, a criação de *features* com base em dados de manutenção não é linear. No entanto, este tipo de *feature engineering* específico caso a caso é muito comum na manutenção preditiva, onde o conhecimento do domínio e a experiência cumprem um papel crucial na compreensão e criação de *features* com relevância.
3. O problema de manutenção preditiva em questão tem como objetivo treinar um modelo para prever falhas, classificando a condição da turbina. Para além dos relatórios em que o óleo já se esta a degradar, o modelo precisa também de relatórios de operação “normal” de modo a ser capaz de perceber a diferença entre os dois. A classificação entre estes dois estados é binária e adicionada como *feature* em cada amostra (*target*):
 - **1**: amostras a vigiar ou com problemas
 - **0**: amostras sem problemas

3.2 Divisão dos dados

Ao trabalhar com dados como relatórios de laboratório, como é o caso, a divisão entre os conjunto de treino, validação e teste deve ser realizada com cuidado, de modo a garantir que as avaliações obtidas correspondem à *performance* real que se deve esperar dos modelos, uma vez que existe um correlação característica inerente entre observações (elevada similaridade entre dados do mesmo tipo de lubrificante).

Em problemas de manutenção preditiva, regra geral, a melhor opção é realizar uma divisão com base no tempo, isto é, escolher um ponto no tempo, treinar o modelo com todos os registo anteriores a esse ponto, utilizando os registos posteriores para validar o modelo. Esta metodologia permite também simular como o modelo se irá comportar realmente na prática.

Assim, na presente aplicação, os registos até 01-04-2023 foram atribuídos ao conjunto de treino e validação, os registos a partir de 01-04-2023 ao conjunto de teste. Dentro desta janela temporal, de todos os dados que foram pré-processados (total de 93 amostras), foi feita uma divisão de 80% para o conjunto de treino e 20% para o conjunto de teste.

Por ultimo, foram escolhidas 20 amostras de óleo aleatórias, para testar a *performance* do modelo em tempo real.

	Treino e Validação	Teste
Janela Temporal	X < 01-04-2023	01-04-2023 < X

Tabela 3.2: Distribuição temporal das amostras.

Amostras (93)	Total	Treino (80%)	Validação (20%)	Teste
Sem Problemas	51	40	11	10
Com problemas	42	33	9	10

Tabela 3.3: Distribuição das amostras.

3.3 Análise dos dados de treino

A análise dos dados de treino revelou que existem determinadas bandas de frequência presentes nos espectros FTIR, que são fortes indicadores do estado das turbinas eólicas. Na figura 3.3, estão representadas várias amostras FTIR sobrepostas, amostras boas e amostras mas, e concluímos que existe a presença de um pico na região de 1750 cm⁻¹ que estava fortemente associado a turbinas em mau estado, indicando a presença de contaminantes. Por outro lado, a ausência desse pico e a presença de outros picos comuns em frequências específicas foram características comuns distintivas de turbinas em bom estado.




Figura 3.3: Gráfico FTIR.

3.4 Detalhes da implementação

Este projeto foi desenvolvido utilizando Python 3, sendo que as redes neurais foram implementadas utilizando a biblioteca Keras, na qual existem diversas redes neurais, previamente treinadas, disponíveis na *Keras Applications*. Os programas foram executados na GPU (*Graphics Processing Units*), com a utilização de um computador com maior poder computacional (Google Colab), devido à carga que os treinos das redes implicam. Em toda a organização de dados e tratamento de resultados foi utilizada a biblioteca Pandas e para as operações básicas foi utilizada a biblioteca Numpy. Os gráficos foram gerados utilizando a biblioteca Matplotlib.

3.5 Escolha e treino do modelo

Escolheu se usar uma rede com uma estrutura densa devido à sua capacidade de generalização. Este tipo de rede consegue lidar com dados de entrada de alta dimensão e complexidade, sendo capaz de aprender a partir de grandes conjuntos de dados.

Uma das principais vantagens das redes neuronais densas é a sua capacidade de aprendizagem de representações hierárquicas. As camadas intermédias podem aprender representações abstratas e de alto nível das características dos dados. Estas representações são posteriormente combinadas nas camadas finais para realizar a classificação. Isto permite que a rede aprenda automaticamente as características mais relevantes para a tarefa de classificação, reduzindo a necessidade de extração manual de características.

A rede neuronal densa é um tipo de algoritmo de *machine learning* que consiste em camadas de neurónios totalmente conectados. Cada neurónio recebe entradas de todos os neurónios da camada anterior e realiza cálculos para gerar uma saída. Foram feitos vários testes à rede com diferentes parâmetros, de modo a minimizar a função de perda e melhorar a precisão da classificação.

Implementação do modelo

O modelo começa por importar as bibliotecas necessárias, incluindo o TensorFlow e o Keras. De seguida, é apresentado um conjunto de dados treino, que contém informações estruturadas sobre cada amostra de óleo: o valor correspondente de cada comprimento de onda (dados FTIR), as horas de uso daquela amostra de óleo na turbina e a condição da amostra.

Depois o pré-processamento dos dados é realizado. Os dados são divididos em conjuntos de treino (80%) e validação (20%).

Na primeira camada foi utilizada a função *layers.Dense()*, que cria uma camada densa (*fully connected*). Tem como primeiro argumento de entrada o número de unidades/neurónios que a camada deve ter, neste caso, são 3451. Como segundo parâmetro é fornecida a função de ativação ReLU (*Rectified Linear Unit*), com o objetivo de introduzir não linearidade na rede neuronal, permitindo que ela aprenda relações complexas nos dados. A última camada é uma camada densa com ativação *Sigmoid*, que é uma função de ativação comum em problemas de classificação binária, pois mapeia os valores de saída para o intervalo entre 0 e 1.

Testes para as camadas intermédias

Para estabelecer a arquitetura da rede neuronal foram adicionadas várias camadas densas, com *dropout* de camadas e regularização dos pesos. Na tabela estão presentes os vários testes feitos, para determinar o número de camadas a usar. Todos os testes foram treinados com o otimizador "adam" e 25 ciclos (*epochs*).

- **Teste 1:** obteve-se uma precisão de treino de 100%, o que sugere que o modelo está a ajustar-se demasiado aos dados de treino. No entanto, a precisão de validação é razoável, indicando que o modelo consegue generalizar para novos dados.

Teste	Camadas intermédias	loss	accuracy	val_loss	val_accuracy
1	0	0.0045	1.0000	6.0930	0.6842
2	1 (dropout 20%)	0.9881	0.9189	14.3608	0.6842
3	1 (128 neurónios com ativação relu)	0.0865	0.9595	4.6282	0.6842
4	1 (128 neurónios com regularizador kernel l2)	1.2807	0.9865	8.7642	0.5789
5	1 (128 neurónios com ativação relu) + 1 (dropout 20%)	0.3269	0.8784	3.3693	0.6842
6	1 (128 neurónios com ativação relu) + 1 (256 neurónios com ativação relu)	0.3345	0.9189	3.3009	0.5263
7	2 (128 neurónios com ativação relu)	0.3260	0.9054	3.0572	0.578
8	2 (128 neurónios com ativação relu) + 1 (dropout 20%)	0.4391	0.9054	7.9874	0.6316
9	3 (128 neurónios com ativação relu)	0.3318	0.9189	1.3860	0.7368
10	1 (128 neurónios com ativação relu) + 1 (256 neurónios com ativação relu)	0.3345	0.9189	3.3009	0.5263
11	1 (128 neurónios com ativação relu) + 1 (256 neurónios com ativação relu) + 1 (dropout 20%)	0.1005	0.9730	2.2103	0.7895

Tabela 3.4: Determinação do numero de camadas intermédias.

- **Teste 2:** a adição de *dropout* ajudou a reduzir o *overfitting*, mas a precisão de validação ainda é baixa. Pode ser necessário ajustar a taxa de *dropout* (foi escolhido 20%, para não aumentar o *overfitting*).
- **Teste 3:** apresenta uma precisão de treino e validação razoável, indicando um bom equilíbrio entre ajuste aos dados de treino e generalização para novos dados.
- **Teste 4:** mostra que a adição de regularização L2 ajudou a controlar o *overfitting* em comparação com o teste 3, mas a precisão de validação é baixa.
- **Teste 5:** a adição de *dropout* parece não ter melhorado a precisão de validação. A taxa de *dropout* pode precisar de ser ajustada.
- **Teste 6:** a adição de uma camada intermédia com 256 neurónios resultou numa queda na

precisão de validação. Isso indica que o modelo está a sofrer de *overfitting*.

- **Teste 7:** sugere que o modelo está em *overfitting*, ou seja, ajusta-se bem aos dados de treino, mas não generaliza para novos dados.
- **Teste 8:** apresenta uma precisão de validação mais baixa em comparação com o teste 9, indicando que a adição de uma camada intermédia extra e *dropout* não melhorou o desempenho.
- **Teste 9:** apresenta uma precisão de validação razoável e uma redução na função de perda. A adição das camadas intermédias ajudou a melhorar o desempenho em relação aos testes 3 e 7.
- **Teste 10:** a adição de uma camada intermédia com 256 neurónios resultou numa queda na precisão de validação. Isso indica que o modelo está a sofrer de *overfitting*.
- **Teste 11:** apresenta uma precisão de treino de 97.30% e uma precisão de validação de 78.95%, indicando um bom equilíbrio entre ajuste e generalização. Com base nos testes feitos, esta arquitetura parece ser a mais promissora, por isso foi a escolhida.

```
x = layers.Dense(3451, activation='relu')(all_features)
x = layers.Dense(128, activation='relu')(x)
x = layers.Dense(256, activation='relu')(x)
x = layers.Dropout(0.2)(x) # Dropout com taxa de 20%
output = layers.Dense(1, activation="sigmoid")(x)
model = keras.Model(all_inputs, output)
model.compile("adam", "binary_crossentropy", metrics=["accuracy"])
```

Figura 3.4: Implementação das camadas do teste 11.

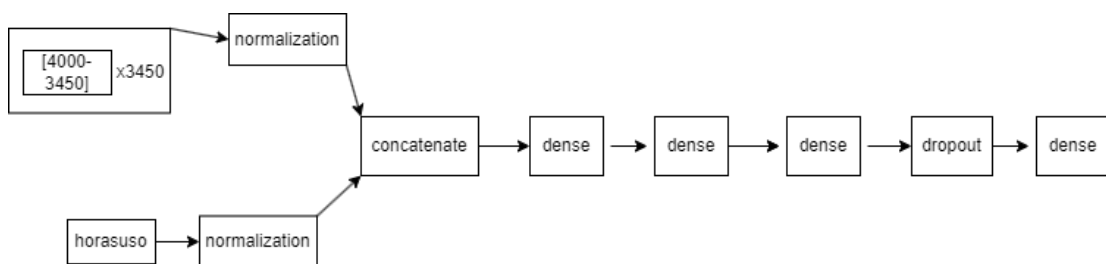


Figura 3.5: Estrutura da rede neuronal, resultado da implementação da figura 3.4.

Escolha dos otimizadores

Os otimizadores são algoritmos que ajustam os pesos da rede neuronal durante o treino. Cada um tem características diferentes em relação à adaptação da taxa de aprendizagem e ao tratamento dos gradientes, o que pode afetar o desempenho e a velocidade de convergência do modelo. Após a definição do número de camadas da rede neuronal, foram testados diferentes otimizadores, mantendo toda a estrutura da rede.

- **Otimizador SGD:** apresentou um desempenho razoável nos dados de treino, com uma boa

Otimizador	loss	accuracy	val_loss	val_accuracy
SGD (learning_rate = 0.001, momentum = 0.9)	0.2025	0.9595	0.7860	0.7368
RMSprop (learning_rate = 0.001)	0.3039	0.9189	1.0508	0.8947
Adam (learning_rate = 0.001)	0.6942	0.6757	1.4676	0.7368

Tabela 3.5: Determinação do melhor otimizador.

precisão. No entanto, nos dados de validação, a precisão foi menor, indicando possíveis dificuldades de generalização.

- **Otimizador Adam:** teve um desempenho inferior nos dados de treino, com uma precisão e perda mais elevadas em comparação com SGD. A precisão nos dados de validação é semelhante à do SGD, indicando dificuldades na generalização.
- **Otimizador RMSprop:** O modelo apresentou um desempenho razoável nos dados de treino, com uma boa precisão. A precisão nos dados de validação também é alta, indicando uma melhor capacidade de generalização em comparação com os outros otimizadores.

Em geral, a rede obteve o melhor desempenho com o otimizador Adam e as configurações comuns. Mostrou uma boa precisão tanto nos dados de treino quanto nos dados de validação, indicando um bom equilíbrio entre o ajuste aos dados de treino e a capacidade de generalização para novos dados. Os outros otimizadores apresentaram um desempenho inferior, com dificuldades de generalização ou resultados inconsistentes entre os conjuntos de treino e validação.

Escolha da taxa de aprendizagem

Testar diferentes taxas de aprendizagem no modelo é uma parte crucial do processo de treino de uma rede neuronal. A taxa de aprendizagem desempenha um papel fundamental no desempenho, determinando a rapidez com que os pesos são ajustados durante o treino. Neste capítulo, vamos explorar a influência das taxas de aprendizagem nos resultados e fazer uma análise abrangente dos efeitos observados.

Para testar diferentes taxas de aprendizagem, irá ser ajustado este hiperparâmetro numa variedade de valores. Irei aumentar gradualmente a taxa de aprendizagem para examinar o seu impacto no desempenho do modelo.

learning_rate	loss	accuracy	val_loss	val_accuracy
0.1	0.6625	0.5946	0.6632	0.5263
0.01	0.6942	0.6757	1.4676	0.7368
0.001	0.3039	0.9189	1.0508	0.8947

Tabela 3.6: Determinação da melhor taxa de aprendizagem.

- **learning_rate = 0.1** observa-se uma diferença considerável entre a precisão no conjunto de treino (0.5946) e a *val_accuracy* no conjunto de validação (0.5263). Isso pode indicar que o modelo está enfrentando dificuldades em generalizar para dados não vistos durante o treino, o que pode ser um sinal de sobreajuste (*overfitting*). A perda (*loss*) também é relativamente alta.
- **learning_rate = 0.01** a precisão no conjunto de treino (0.6757) é um pouco maior do que o teste anterior, mas ainda há uma diferença significativa em relação à *val_accuracy* no conjunto de validação (0.7368). A perda (*loss*) e a *val_loss* também são consideravelmente altas. Novamente, isto pode indicar sobreajuste e dificuldade do modelo em generalizar.
- **learning_rate = 0.001** observa-se uma melhoria significativa na precisão tanto no conjunto de treino (0.9189) como no conjunto de validação (0.8947). A diferença entre as duas métricas é pequena, indicando uma melhor capacidade de generalização. No entanto, a *val_loss* é relativamente alta, o que pode indicar que o modelo ainda pode ser melhorado.

Em geral, os resultados dos três testes indicam a presença de sobreajuste (*overfitting*), pois há uma diferença considerável entre as medidas de treino e validação, especialmente nos dois primeiros testes. Isto é devido à quantidade reduzida de dados de treino. O teste 3 apresenta uma melhoria significativa em relação aos outros dois, por isso foi o escolhido.

Escolha do numero de épocas

Testar diferentes números de épocas no modelo desempenha um papel crucial na determinação do momento ideal para terminar o treino. As épocas representam o número de vezes que o modelo percorre todo o conjunto de treino durante o processo de aprendizagem. Neste capítulo, irá ser testada a influência do número de épocas nos resultados e feita uma análise abrangente dos efeitos observados.

Para testar diferentes números de épocas, ajustaremos este hiperparâmetro numa variedade de valores: 10, 30, 50 e 100.

Um aspeto importante a considerar é a análise das curvas de aprendizagem ao longo das épocas. A evolução da função de perda e da precisão do modelo irá ser monitorizada em cada época para identificar padrões e tendências. Isso irá permitir compreender se o modelo está a convergir corretamente, se há sinais de *overfitting* ou *underfitting* e se é necessário ajustar o número de épocas.

Além disso, irá ser testada uma técnicas de paragem antecipada (*early stopping*). Esta técnica monitoriza o desempenho do modelo no conjunto de validação e interrompe o treino quando não há mais melhorias significativas. Espera-se que a aplicação desta técnica ajude a determinar o número ideal de épocas, evitando o *overfitting* e alcançando uma melhor generalização.

- **10 épocas** Com um número relativamente baixo de épocas, o modelo apresentou uma precisão razoável, mas ainda há margem para melhorias, uma vez que a precisão de validação é menor do que a de treino.

Nº Épocas	loss	accuracy	val_loss	val_accuracy
10	1.9130	0.7027	1.9796	0.6316
25	0.3039	0.9189	1.0508	0.8947
30	0.1098	0.9324	7.4536	0.4737
50	9.3035e-04	1.0000	8.0071	0.6842
100 + early stopping (patience=5, verbose=1)	0.1169	0.9324	5.2059	0.7368

Tabela 3.7: Determinação do número de épocas.

- **25 épocas** Com um número maior de épocas, o modelo melhorou significativamente sua precisão, tanto no conjunto de treino quanto no conjunto de validação. Isto indica que o modelo está a aprender melhor com o aumento do número de épocas.
- **30 épocas** O modelo apresentou uma boa precisão de treino, mas a precisão de validação diminuiu significativamente. Isto pode indicar que o modelo está a sofrer de *overfitting*, ou seja, está se a ajustar muito bem aos dados de treino, mas não está a generalizar para novos dados.
- **50 épocas** Com um número maior de épocas, o modelo alcançou uma precisão perfeita de treino, mas a precisão de validação ainda é relativamente baixa. Isto também pode indicar a presença de *overfitting*.
- **100 épocas com *early stopping*** Neste teste, foi utilizado o recurso de *early stopping*, que para o treino se não houver melhoria na precisão de validação durante um determinado número de épocas. O modelo foi interrompido após 21 épocas. Embora a precisão de validação tenha melhorado em relação ao teste 3, ainda pode haver espaço para melhorias.

Com base nestas análises, podemos concluir que aumentar o número de épocas pode melhorar a precisão do modelo, mas também pode levar ao *overfitting*. O uso do *early stopping* pode ser útil para interromper o treino e evitar o *overfitting* quando a precisão de validação não está a melhorar. É importante encontrar um equilíbrio entre o número de épocas e a precisão do modelo para evitar o *overfitting* e garantir uma boa generalização para novos dados. Entre os testes fornecidos, o teste que obteve o melhor desempenho em termos de precisão de validação foi o teste realizado com 25 épocas. Neste teste, o modelo alcançou uma precisão de treino superior às outras (val_accuracy: 0.8947), indicando que foi capaz de se ajustar muito bem aos dados de validação.

3.6 Avaliação do modelo

Esta secção apresenta a avaliação do modelo desenvolvido para a classificação de amostras, com base no conjunto de dados de validação. A matriz de confusão 2.26, será utilizada como uma métrica fundamental para avaliar o desempenho do modelo implementado ao longo do capítulo 3.5.

O objetivo do modelo é classificar corretamente as amostras como boas ou más. Para fins de

avaliação, utilizámos um conjunto de validação composto por 20 exemplos introduzido na secção 3.2. Estas amostras foram selecionadas de forma aleatória e de uma janela temporal recente, para representar da melhor forma o comportamento do modelo em tempo real.

No contexto desta avaliação, um TP ocorre quando o modelo classifica corretamente uma amostra como boa, enquanto um TN ocorre quando o modelo classifica corretamente uma amostra como má. Por outro lado, um FP é observado quando o modelo classifica erroneamente uma amostra como boa, quando na verdade é má, e um FN ocorre quando o modelo classifica erroneamente uma amostra como má, quando na verdade é boa.

		Output do modelo	
		Com problemas	Sem problemas
Real	Com problemas	9	1
	Sem problemas	4	6

Figura 3.6: Matriz de confusão do modelo final com os testes de verificação.

A partir destes valores, é possível calcular várias métricas para avaliar o desempenho do modelo (introduzidas em 2.5.2), tais como a acurácia, a precisão, a sensibilidade e F1 score. Estas métricas fornecem uma visão mais completa do desempenho do modelo em relação às diferentes classes:

- **Acurácia: 67%** significa que o modelo classificou corretamente 67% dos casos em geral.
- **Precisão: 50%** indica que metade das previsões positivas do modelo foram realmente positivas, enquanto a outra metade foi classificada incorretamente.
- **Sensibilidade: 80%** significa que o modelo conseguiu identificar corretamente 80% dos casos com problemas.
- **F1 score: 61,5%** quanto maior o valor melhor é o equilíbrio entre precisão e sensibilidade. Neste caso, o valor de 0,615 sugere que há espaço para melhorias no desempenho do modelo em relação ao equilíbrio entre estas duas métricas.

3.7 Conclusões

A área de manutenção da Vestas, categoriza os relatórios de manutenção por dias de necessidade de manutenção: 30, 60, 90, 180 e 365. O que a partir do cruzamento dos resultados do laboratório com os resultados do meu modelo, me permitiu construir o gráfico da figura 3.7, e podemos concluir que o modelo desenvolvido demonstrou ter capacidade para ser uma boa ferramenta para a equipa de manutenção.




Figura 3.7: Relação do modelo com a necessidade de manutenção.

Ao utilizar os coeficientes da transformada de *Fourier* das amostras de óleo como entrada para o modelo, foi possível obter uma classificação que reflete o estado de cada turbina. Através da análise da porcentagem fornecida pelo modelo para cada amostra, a equipa de manutenção pôde priorizar as turbinas que necessitam de atenção imediata (porcentagens superiores).

A correlação entre as porcentagens fornecidas pelo modelo e os relatórios das análises validou a eficiência do modelo como um indicador fiável (apesar de precisar de ser treinado com mais amostras, para melhorar a sua generalização). Esta conclusão confirma que o modelo pode fornecer uma avaliação precisa do estado das turbinas com base nos dados FTIR do óleo.

Esta abordagem de manutenção preditiva com inteligência artificial traz benefícios significativos para a área de manutenção. Ao utilizar o modelo como um apoio, podem tomar decisões mais fundamentadas e gerir a manutenção de uma forma mais eficiente. Como já foi falado anteriormente, isto resulta numa melhor utilização dos recursos disponíveis e numa potencial redução dos custos associados à manutenção.

No entanto, é importante destacar que o modelo tem as suas limitações. Ele depende dos dados FTIR das amostras de óleo e por consequência só avalia o estado interior da caixa de velocidades, que neste caso foi o tipo de dados que treinamos o modelo (ou seja, o modelo só consegue avaliar um componente de cada vez).

Para concluir, a aplicação prática do modelo desenvolvido mostrou-se promissora e viável para apoiar a equipa de manutenção.

Capítulo 4

Conclusões e Trabalho Futuro

4.1 Conclusões

A presente dissertação permitiu retirar um conjunto de conclusões sobre o trabalho realizado. Foi possível perceber de que modo as ferramentas de Inteligência Artificial, mais concretamente *Machine Learning*, podem ser aplicadas na área da manutenção, com o advento da Indústria 4.0, permitindo uma movimentação no sentido de uma manutenção preditiva e prescritiva, sob pena de perda de competitividade. Espera-se que a necessidade de um engenheiro eletrotécnico conhecer estas ferramentas tenha sido evidenciada. O conjunto de dados utilizado é chave para a resolução de problemas de *Machine Learning*. Uma escolha sensata de quais os dados a usar e como tratá-los é crucial para melhorar o desempenho dos algoritmos. A divisão dos dados em conjuntos de treino, validação e verificação é fundamental para que a performance real dos sistemas de *Machine Learning* não seja inferior às expectativas geradas por uma avaliação incorreta dos resultados dos modelos. Demonstrou-se uma metodologia que permitiu mostrar, a partir de dados de tipos e fontes não muito comuns, como é possível visualizá-los e tratá-los com o objetivo de aplicar ferramentas de Inteligência Artificial, neste caso, *Machine Learning*. Abordou-se as vantagens e desvantagens dos diferentes tipos de manutenção, uma vez que a ocorrência de falhas é comum durante o ciclo de vida de uma determinada máquina, e escolher os melhores métodos de manutenção é imprescindível para a vida útil do equipamento.

A implementação foi realizada com recurso à linguagem de programação Python. Esta linguagem de programação contém numerosas bibliotecas disponíveis (*Matplotlib*, *Numpy*, *Pandas*, *tensorflow*) e uma extensa bibliografia (*keras*) que demonstra como estas podem ser aplicadas em projetos de *Machine learning*. Assim, o Python apresenta-se com uma ótima ferramenta para a aplicação de todos os conceitos apresentados ao longo da dissertação.

Não se deve esperar que o *Machine Learning* resolva todos os problemas da área da manutenção, no entanto, o seu potencial não deve ser desprezado. Os modelos de *Machine Learning* são apenas uma parte de um processo maior para resolver um problema específico e é importante manter um panorama geral em mente. Ao aprofundar os aspetos técnicos do *Machine Learning*, é

fácil perder de vista os objetivos finais. É importante manter em mente todas as suposições criadas, de forma explícita ou implícita, quando são construídos modelos de *Machine Learning*.

Casos de estudo como este podem ter um papel importante nesta área, ainda que, o acesso a conjuntos de dados reais é frequentemente uma barreira. Casos de estudo permitem perceber como um determinado fenómeno é influenciado pelo contexto em que se encontra assim como obter informações detalhadas acerca de um cenário específico, possibilitando uma análise mais profunda dessa situação. Um dos objetivos é compreender a peculiaridade do caso de modo a extrapolar conclusões para outras situações e compreender a relação entre as variáveis e o modelo. Mesmo em contextos altamente específicos, algumas das conclusões podem ser extrapoladas para situações mais amplas. Apesar do progresso nos métodos de aquisição de dados e ferramentas de Inteligência Artificial, a plena utilização dos recursos fornecidos por estes é, ainda, incipiente. Os sistemas estão longe de atingir o grau de desempenho e robustez necessários para automação total na maior parte dos casos. O fator humano é de importância central. Sem a ajuda de mão de obra especializada não seria possível rastrear com eficiência problemas em sistemas críticos. Contudo, é recomendável que as duas fontes de conhecimento sejam combinadas de modo a produzir estratégias de manutenção mais confiáveis e precisas. Ainda, a existência de uma visão no sentido de desenvolver sistemas que possam trazer maior produtividade ao elemento humano. Um sistema de prognóstico será eventualmente capaz de reduzir a carga de trabalho desnecessária e aliviar pequenos erros humanos, sendo que, no entanto, poderá igualmente criar lacunas induzidas pela automação, produzir alarmes falsos e, talvez mais importante, aumentar a carga de trabalho mental necessária para executar a monitorização adicional do sistema. De modo a alcançar o equilíbrio correto entre a automação e o fator humano, é importante garantir que a tecnologia esteja presente para ajudar o especialista naturalmente, deixando-o ser a autoridade final na determinação de uma possível falha. O operador deve poder substituir as recomendações do sistema e usar suas próprias habilidades e experiência quando necessário. O difícil equilíbrio entre intervenção humana e automação é mais facilmente alcançado se os sistemas estiverem equipados com modelos fáceis de interpretar e entender. No entanto, a falta de transparência do processo de decisão inerente a muitos dos modelos de *Machine Learning* é inevitável e, portanto, o desconforto que possa advir deste facto tem de ser ultrapassado com, por exemplo, o uso de métricas de avaliação poderosas e demonstrações práticas de sucesso preditivo. Para que a utilização de ferramentas de Inteligência Artificial na área da manutenção seja viável, as consequências provenientes dessa aplicação devem ser significativas, para que o custo de desenvolvimento, implementação e utilização seja justificado. Deve existir uma lacuna significativa entre o desempenho de qualquer estratégia existente e aquele que pode ser alcançado através da aplicação de modelos de *Machine Learning*. As tecnologias preditivas avançadas necessitam de ser direcionadas para as oportunidades mais significativas de modo a permitir uma melhoria no desempenho geral da organização. Estes métodos devem ser capazes de atender não só às necessidades técnicas mas também às necessidades económicas.

A transformação de uma indústria deve ser um processo contínuo e abrangente, que vai além da melhoria de tecnologias, tendo que afetar toda a cadeia envolvente e sequencial de processos, modelos de negócio, aspetos organizacionais e de gestão. Deve-se reter que o investimento na

digitalização poderá trazer melhorias em produtividade e eficiência, mas os benefícios virão apenas quando acompanhados da melhoria de desempenho organizacional e visão nas empresas.

4.2 Trabalhos Futuros

Há várias direções promissoras para expandir e aprimorar o trabalho atual de manutenção preditiva com o algoritmo desenvolvido. Entre os principais pontos a serem explorados, destaca-se a escalabilidade do algoritmo para lidar com outros tipos de dados provenientes de diferentes sensores e componentes das turbinas eólicas. Isso permitiria uma análise abrangente da condição das turbinas, considerando múltiplos indicadores de desgaste ou falha.

Outro ponto relevante é o desenvolvimento de um sistema em tempo real que possa receber os dados dos sensores de monitorização das turbinas em operação e fornecer previsões contínuas, permitindo uma deteção e resposta imediatas a possíveis falhas ou necessidades de manutenção.

Para fortalecer a aplicabilidade do modelo, este irá ser escalado e irão ser realizadas validações experimentais no terreno para realmente perceber o impacto na gestão da manutenção e nos custos associados.

Estas sugestões refletem possibilidades interessantes para a evolução do trabalho, considerando a adaptabilidade do algoritmo, a implementação em tempo real e a validação experimental. Esses avanços podem aprimorar a eficácia e a confiabilidade do modelo, contribuindo para uma manutenção mais eficiente e principalmente uma redução de custos no setor de energia eólica.

Bibliografia

- [1] A. Gilchrist, *Industry 4.0: The Industrial Internet of Things*, 1st Edition, Apress, USA, 2016.
- [2] K. Kobbacy, D. Murthy, *Complex System Maintenance Handbook*, Springer, 2008. doi : 10.1007/978-1-84800-011-7.
- [3] J. Ferreira, F. Martins, *Ventos de mudança – a energia eólica em portugal*. (2009).
- [4] M. Paolanti, L. Romeo, A. Felicetti, A. Mancini, E. Frontoni, J. Loncarski, Machine learning approach for predictive maintenance in industry 4.0, in: 2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA), 2018, pp. 1–6. doi:10.1109/MESA.2018.8449150.
- [5] A. Muller, S. Guido, *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O’Reilly Media, Incorporated, 2018.
URL <https://books.google.pt/books?id=jGdXswEACAAJ>
- [6] K. P, Machine learning approach to predictive maintenance in manufacturing industry - a comparative study, *Journal of Soft Computing Paradigm* 2 (2021) 246–255. doi:10.36548/jscp.2020.4.006.
- [7] L. F. G. Pereira, *Previsão de falhas em empanques mecânicos da refinaria de matosinhos usando modelos de machine learning*, Master’s thesis, FEUP (September 2018).
URL <https://repositorio-berto.up.pt/handle/10216/116039>
- [8] A. H. Beneduzzi., *Procedimentos de coletas de óleo para análise preditiva de turbinas eólicas*, Master’s thesis, UNESP, [Accessed 11-08-2023] (February 2012).
URL <https://repositorio.unesp.br/handle/11449/94505?show=full>
- [9] M. Garan, K. Tidriri, I. Kovalenko, A data-centric machine learning methodology: Application on predictive maintenance of wind turbines, *Energies* 15 (3) (2022). doi:10.3390/en15030826.
URL <https://www.mdpi.com/1996-1073/15/3/826>
- [10] D. F. F. D. Fernandes, *Uma abordagem para manutenção preditiva baseada em sistemas multiagente e machine learning*, Master’s thesis, FCT (2020).
URL <https://run.unl.pt/handle/10362/108614>

- [11] J. Eriksson, Machine learning for predictive maintenance on wind turbines, Master's thesis, Linköping University (2020).
URL <https://api.semanticscholar.org/CorpusID:215751520>
- [12] S. Givnan, C. Chalmers, P. Fergus, S. Ortega, T. Whalley, Real-time predictive maintenance using autoencoder reconstruction and anomaly detection, ArXiv abs/2110.01447 (2021).
URL <https://api.semanticscholar.org/CorpusID:238259886>
- [13] Z. M. Çınar, A. Abdussalam Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, B. Safaei, Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0, Sustainability 12 (19) (2020). doi:10.3390/su12198211.
URL <https://www.mdpi.com/2071-1050/12/19/8211>
- [14] E. P. D. Jr., Tolerância a falhas ou dependabilidade., <https://www.inf.ufpr.br/elias/sisdis/Capitulo2Dependabilidade.pdf> (Outubro 2022).
- [15] J. Cabral, Organização e gestão da manutenção: dos conceitos á prática..., LIDEL, 2006.
URL <https://books.google.pt/books?id=j-NOPgAACAAJ>