



Modelação e estudo de algoritmos de manutenção preditiva em equipamento de fresagem

FÁBIO MIGUEL PINTO SANTOS

outubro de 2025

MODELAÇÃO E ESTUDO DE ALGORITMOS DE MANUTENÇÃO PREDITIVA DE EQUIPAMENTO DE FRESAGEM

Fábio Miguel Pinto Santos

Departamento de Engenharia Eletrotécnica

Mestrado em Engenharia Eletrotécnica e de Computadores

Área de Especialização em Sistemas e Planeamento Industrial

Relatório elaborado para satisfação parcial dos requisitos da Unidade Curricular de
Tese/Dissertação do Mestrado em Engenharia Eletrotécnica e de Computadores

Candidato: Fábio Miguel Pinto Santos, Nº 1090476, 1090476@isep.ipp.pt

Orientação científica:

Professora Susana Nicola, sca@isep.ipp.pt

Professor Ivo Pereira, iap@isep.ipp.pt



Departamento de Engenharia Eletrotécnica
Mestrado em Engenharia Eletrotécnica e de Computadores
Área de Especialização em Sistemas e Planeamento Industrial

2025

Agradecimentos

A conclusão deste trabalho representa o culminar de mais uma etapa da minha vida académica, que só foi possível com o apoio, incentivo e dedicação de pessoas especiais, às quais deixo aqui o meu mais sincero agradecimento.

Em primeiro lugar, agradeço aos meus pais, pelo investimento incondicional na minha formação ao longo dos anos, sempre com palavras de incentivo e confiança.

À minha namorada, pela motivação e incentivo muitas vezes em modo de picardia saudável que, de forma surpreendente, me impulsionou a continuar quando o cansaço já ameaçava e o foco se ia desvanecendo.

Aos meus orientadores, deixo um agradecimento especial pela orientação, paciência e toda a disponibilidade ao longo destes meses que levou o processo. Foram fundamentais, na elaboração desta dissertação, e deram-me forças e confiança para acreditar na conclusão deste trabalho.

Por fim, um último agradecimento à minha entidade patronal, que desde o primeiro dia em que integrei a empresa sempre me incentivaram na conclusão da dissertação.

A todos, o meu muito obrigado.

Resumo

A indústria segue a sua constante transformação digital, alavancada por conceitos como a Indústria 4.0, *Internet of Things (IoT)*, Big Data ou agora e mais atual a Inteligência Artificial. Este novo paradigma industrial promove a interligação entre sistemas físicos e digitais, criando as *Smart Factories* cada vez mais automatizadas onde a tomada de decisão é cada vez mais baseada em dados. Aqui surge a manutenção preditiva, uma aplicação estratégica que tem como finalidade a antecipação de falhas em equipamentos recorrendo a dados obtidos e analisados em tempo real, reduzindo tempos de paragens não planeados, custos de operação e respetivos riscos associados à produção.

A presente dissertação está desenvolvida no âmbito da manutenção preditiva, que utiliza abordagens avançadas de análise de dados, por forma a prever quando e onde poderá ocorrer uma avaria. Para isto tem um papel essencial as técnicas de *Machine Learning*, que permite a construção de modelos capazes de identificar padrões anormais, classificando-os e estimando a vida útil dos ativos em avaliação. Suportado por algoritmos como o *Random Forest*, o *Gradient Boosting*, entre outros, as organizações conseguem extrair uma quantidade de dados históricos e operacionais, convertendo-os em conhecimento.

Em termos de resultados da dissertação, realizou-se a análise de vários modelos de *Machine Learning* e avaliou-se quais os tipos de algoritmos mais capacitados de implementar em um caso real de Manutenção Preditiva, onde observamos os bons resultados que alguns dos algoritmos nos fornece, caso do *Gradient Boosting*, *Random Forest* e o *Neural Network*.

Palavras-Chave

Manutenção Preditiva, Modelação, Estudo de algoritmos, Fábricas Inteligentes, Indústria 4.0, Aprendizagem Automática.

Abstract

The industry continues its constant digital transformation, driven by concepts such as Industry 4.0, the Internet of Things (IoT), Big Data and, more recently, Artificial Intelligence. This new industrial paradigm promotes the interconnection of physical and digital systems, creating increasingly automated Smart Factories where decision-making is increasingly based on data. This is where predictive maintenance comes in, a strategic application that aims to anticipate equipment failures using data obtained and analysed in real time, reducing unplanned downtime, operating costs and the associated risks to production.

This dissertation is developed within the scope of predictive maintenance, which uses advanced data analysis approaches to predict when and where a failure may occur. Machine learning techniques play an essential role in this, allowing the construction of models capable of identifying abnormal patterns, classifying them and estimating the useful life of the assets under evaluation. Supported by algorithms such as Random Forest and Gradient Boosting, among others, organisations are able to extract a wealth of historical and operational data, converting it into knowledge.

In terms of the dissertation's results, a model was analysed and the types of algorithms best suited for implementation in a real case of Predictive Maintenance were evaluated, where we can observe the good results that some of the algorithms provide us, such as Gradient Boosting, Random Forest, and Neural Network.

Keywords

Predictive maintenance, modelling, algorithm study, smart factories, Industry 4.0, machine learning.

Índice

AGRADECIMENTOS.....	V
RESUMO.....	VII
PALAVRAS-CHAVE.....	VII
ABSTRACT.....	IX
KEYWORDS.....	IX
ÍNDICE DE FIGURAS	XII
ACRÓNIMOS	1
1. INTRODUÇÃO.....	2
1.1.CONTEXTUALIZAÇÃO	2
1.2.OBJETIVOS	2
1.3.CALENDARIZAÇÃO.....	3
1.4.ORGANIZAÇÃO DO RELATÓRIO.....	3
2. REVISÃO BIBLIOGRÁFICA.....	5
2.1.INDÚSTRIA 4.0	5
2.2.IMPLEMENTAÇÃO DA INDÚSTRIA 4.0	5
2.3.DEFINIÇÃO DE MANUTENÇÃO.....	6
2.4.TIPOS DE MANUTENÇÃO	7
2.4.1.MANUTENÇÃO CORRETIVA	7
2.4.2.MANUTENÇÃO PREVENTIVA.....	8
2.4.3.MANUTENÇÃO PREDITIVA	8
2.5.TÉCNICAS DA MANUTENÇÃO PREDITIVA	9
2.5.1.DESAFIOS DA MANUTENÇÃO PREDITIVA	10
2.5.2.INTELIGÊNCIA ARTIFICIAL.....	11
2.5.2.1.CONCEITOS E TÉCNICAS DE APRENDIZAGEM	11
2.5.3.IMPACTO DA IA NA MANUTENÇÃO PREDITIVA	12
2.6.APRENDIZAGEM AUTOMÁTICA	13
2.6.1.ALGORITMOS DE APRENDIZAGEM AUTOMÁTICA.....	14
3. DESENVOLVIMENTO	19
3.1.METODOLOGIA	20
3.2.ANÁLISE DO PROBLEMA	21
3.3.COMPREENSÃO E PREPARAÇÃO DOS DADOS	22
3.4.MODELAÇÃO DO PROBLEMA	24

3.5.AVALIAÇÃO	30
4. CONCLUSÕES	38
REFERÊNCIAS BIBLIOGRÁFICAS	39

Índice de Figuras

Figura 1 – Calendarização da Dissertação	3
Figura 2 – Evolução das práticas de manutenção (Achouch et al., 2022)	7
Figura 3 - Gráfico de Regressão Logística(Raquel Araújo, 2022)	15
Figura 4 - Estrutura de Árvore de Decisão (Fonte: Autor)	15
Figura 5 - Diagrama do funcionamento da Floresta Aleatória (GOMES TELES, 2025)	16
Figura 6 - Diagrama de Fluxo do método Gradient Boost (T. Zhang et al., 2021)	17
Figura 7 – Diagrama de Fluxo de uma Rede Neuronal (Santos, 2022)	18
Figura 8 – Métricas de desempenho após implementação de Análise Preditiva, adaptado de (Bennett, 2025)	19
Figura 9 – 6 etapas do CRISP-DM (Lima, 2020)	21
Figura 10 – Seleção de variáveis do Dataset	22
Figura 11 – Divisão do Dataset em 80/20	23
Figura 12 – Modelo aplicado no Orange	24
Figura 13 – Parâmetros do algoritmo <i>Logistic Regression</i>	25
Figura 14 – Parâmetros do algoritmo <i>Tree</i>	26
Figura 15 – Parâmetros do algoritmo <i>Random Forest</i>	27
Figura 16 – Parâmetros <i>Gradient Boosting</i>	28
Figura 17 – Parâmetros Neural Network	29
Figura 18 - Desempenho dos algoritmos	31

Figura 19 - Análise dos algoritmos ao nível da Precisão	31
Figura 20 – Análise dos algoritmos ao nível do <i>recall</i>	32
Figura 21 – Análise dos algoritmos ao nível do F1-score	32
Figura 22 - Curva ROC	33
Figura 23 - Matriz Confusão <i>Gradient Boosting</i>	34
Figura 24 – Matriz confusão <i>Logistic Regression</i>	35
Figura 25 – Matriz confusão <i>Neural Network</i>	35
Figura 26 -Matriz confusão <i>Random Forest</i>	36
Figura 27 – Matriz confusão <i>Tree</i>	36

Acrónimos

CRISP-DM - *Cross-Industry Standard Process for Data Mining*

FP - *False Positive*

IA - *Inteligência Artificial*

IoT - *Internet of Things*

ML - *Machine Learning*

MP - *Manutenção Preditiva*

OEE - *Overall Equipment Effectiveness*

ROC - *Receiver Operating Characteristic*

TF - *True False*

TP - *True Positive*

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

Este projeto de dissertação enquadra-se no Mestrado em Sistemas e Planeamento industrial e tem como tema a modelação e estudo de algoritmos de manutenção preditiva de equipamento de fresagem. Neste documento será abordado o tema da manutenção, com incidência na manutenção preditiva, e de que forma pode ser útil em processos industriais.

Será estudado e alvo de avaliação um problema de modelação de um equipamento de fresagem, e qual o algoritmo que nos permite a melhor abordagem de forma a obter o melhor rendimento do equipamento em análise e a sua respetiva performance.

1.2. OBJETIVOS

Foram vários os objetivos definidos nesta dissertação. Em primeiro lugar a absorção de novos conhecimentos, pois este além de ter sido sugerido pelos orientadores, é algo que a indústria já começa a exigir a todos os fabricantes de maquinaria, e estes atualmente já começam a dotar os seus equipamentos com ferramentas capazes de detetar falhas e erros antes mesmo que ocorram.

Outro dos objetivos propostos neste trabalho, foi a modulação de um problema real, para a avaliação do algoritmo mais indicado que ao ser aplicado nos permitisse detetar e minimizar ao máximo os tempos de paragem de máquina, pois este é um dos grandes inconvenientes quando falamos de produções em massa onde é fulcral aumentar ao máximo o tempo de máquina em atividade.

Também com este trabalho, foi possível compreender vantagens e desvantagens deste tipo de manutenção, assim como problemas e desafios que se encontram atualmente para a aplicação deste tipo de manutenção.

1.3. CALENDARIZAÇÃO




Figura 1 – Calendarização da Dissertação

O projeto teve no total 42 semanas, começando com o envio da proposta, e atribuição dos orientadores, passando por toda a recolha bibliográfica de auxílio ao estudo da Arte. Com algumas semanas um pouco mais atarefadas a nível laboral onde não foi possível atribuir à dissertação tanto tempo, passou-se à escrita da Revisão Bibliográfica e por fim concluído com a avaliação de vários algoritmos aplicados ao modelo. A Figura 1 mostra o cronograma de todas as etapas e tarefas do trabalho.

1.4. ORGANIZAÇÃO DO RELATÓRIO

A dissertação está estruturada da seguinte forma: no capítulo 1 é apresentada a introdução do trabalho onde o contextualizamos, definimos os objetivos e a respetiva calendarização.

No capítulo 2 é abordado o estado da arte, aqui apresentamos a definição de manutenção, dando ênfase à manutenção preditiva, e tecnologias utilizadas para o auxílio, nomeadamente a interligação com a Indústria 4.0 e a Inteligência Artificial com a aprendizagem de máquina.

No capítulo 3 é apresentada a análise a um problema de modelação de um equipamento de fresagem. São aplicados diferentes algoritmos ao modelo utilizando o software Orange e avaliados com a finalidade de compreender qual o que nos garante melhor performance de resultados.

Por fim no capítulo 4 é exposta uma conclusão sobre a globalidade do trabalho.

2. REVISÃO BIBLIOGRÁFICA

2.1. INDÚSTRIA 4.0

A Indústria 4.0 atualmente tem como princípios a capacidade de operação em tempo real, onde computadores e equipamentos industriais estão conectados diretamente entre eles tomando decisões sem a intervenção humana, coordenando-se uns com os outros através da Internet (Achouch et al., 2022)

Isto cria um sistema produtivo mais inteligente, ampliando a capacidade de resolução de problemas sem a necessidade de interferência humana. Contudo é fundamental uma troca de informação constante em todo o ciclo produtivo (De Souza et al., 2022)

2.2. IMPLEMENTAÇÃO DA INDÚSTRIA 4.0

A implementação para a criação de fábricas mais inteligentes, flexíveis, eficientes e conectadas tem como base alguns dos seguintes pilares tecnológicos:

- Rastreabilidade: Possibilidade de obter a informação do produto em todas as etapas do seu ciclo de fabrico (De Souza et al., 2022);
- (“Internet of thing (IoT)”): Permite a conectividade de todos os equipamentos presentes no chão de fábrica entre si e o exterior (De Souza et al., 2022);
- “Big data e Analytics”: Gera conhecimento e valor a partir do armazenamento de dados de produção, identificando tendências e recomendações para a otimização dos processos. É uma ferramenta importante para tomadas de decisão dos equipamentos e máquinas na cadeia produtiva (De Souza et al., 2022).

- “Cloud computing”: Permite o acesso de forma descentralizada a grandes volumes de informação através da internet para a tomada de decisões estratégicas (De Souza et al., 2022).
- Manutenção Preditiva: analisa os dados e planeia a manutenção por forma a evitar paragens desnecessárias (De Souza et al., 2022).

Estas tecnologias mencionadas têm impacto significativo na produtividade, pois aumenta a eficiência do uso de recursos e no desenvolvimento de produtos em larga escala (De Souza et al., 2022).

2.3. DEFINIÇÃO DE MANUTENÇÃO

A manutenção consiste em um conjunto de ações técnicas e administrativas que visam assegurar o bom funcionamento dos equipamentos e dos sistemas. Estas ações são realizadas normalmente e de forma periódica segundo recomendações, por forma a evitar paragens e reduções de rendimento.

A crescente competitividade dos mercados, obriga as empresas a ser cada vez mais competentes nos seus processos, de forma a serem mais eficientes e os tempos de máquina mais otimizados. É por aqui que começa a entrar a adoção por parte das empresas de meios de prevenção contra paragens não planeadas das máquinas, o que traz elevados custos associados.

Por este facto, a importância da manutenção é bem conhecida, pois com a sua realização garantimos que a máquina mantém a sua fiabilidade, sendo esta crucial para minimizar o tempo de inatividade e as perdas de produção, assim como melhorar a eficiência operacional do equipamento, garantindo a segurança do local de trabalho e prolongando a sua vida útil (Salawu et al., 2023).

2.4. TIPOS DE MANUTENÇÃO

Ao longo das revoluções industriais, foram evoluindo os conceitos/tipos de manutenção, de forma a conseguir os melhores resultados.

Conforme se pode ver na Figura 2, são conhecidos 3 tipos de manutenção, entre elas estão a corretiva, a preventiva e a que abordaremos com mais destaque neste trabalho a Preditiva (Achouch et al., 2022)

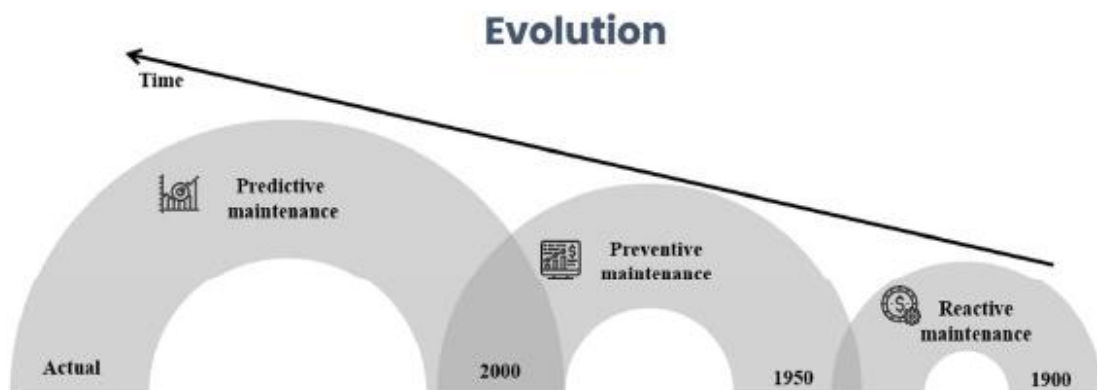


Figura 2 – Evolução das práticas de manutenção (Achouch et al., 2022)

2.4.1. MANUTENÇÃO CORRETIVA

Esta trata-se de uma prática não planeada e normalmente ocorre após suceder uma falha no equipamento, sendo então realizada uma reparação parcial para que o equipamento volte a operar. Normalmente este tipo de abordagem está associada a baixos custos, no entanto como apenas é realizada após falha traz associado o risco de:

- Não utilização do equipamento por um período mais elevado;
- Perdas de receitas;
- Custo incrementado do valor de reparação e tempo associado à mesma;
- Maior custo de reparação (Molêda et al., 2023).

2.4.2. MANUTENÇÃO PREVENTIVA

Sendo esta uma prática planeada, ela é realizada de forma mais frequente e como tal programada por períodos estipulados segundo recomendações dos fabricantes e dos manuais, que evitam, ainda que possam acontecer, paragens não planeadas. Incluem tipicamente tarefas de lubrificação, ajustes, calibrações, mudanças de óleo ou outros diagnósticos. A manutenção preventiva assegura o bom estado do equipamento e reduz o risco de eventuais paragens, no entanto, não protege contra falhas inesperadas.

Associado a este tipo de manutenção, e como em alguns casos as recomendações dos fabricantes é substituir algumas das peças, é possível que sejam substituídas algumas que ainda estavam longe da sua falha, o que acarretam custos associados e nem por isso a certeza de que a peça substituída tenha maior tempo de vida (Molêda et al., 2023).

2.4.3. MANUTENÇÃO PREDITIVA

Esta é uma outra prática de manutenção que pode ser considerada planeada. Ela é também conhecida como “on-line monitoring”, “condition-based maintenance”, or “riskbased maintenance”.

Consiste na tentativa de prever o momento em que uma máquina é suscetível de sofrer uma avaria, baseando-se em técnicas de análise de dados e na Inteligência artificial (IA) para a sua previsão. Com a recolha de dados afetos às condições de funcionamento das máquinas por intermédio de sensores de vários tipos, é possível utilizando modelos de IA, identificar anomalias e determinar qual será o seu tempo de vida útil estimado até à falha (Andrianandrianina Johanesa et al., 2024).

Sendo a manutenção um dos parâmetros medidos e avaliado pelo OEE (*Overall Equipment Effectiveness*), que mede a eficiência dos equipamentos e processos, a aplicação desta prática ajudará a tornar tudo mais eficiente e com isso um melhor índice OEE, reduzindo tempos de paragem não planeados (Alexandre & Rebelo, n.d.).

2.5. TÉCNICAS DA MANUTENÇÃO PREDITIVA

Existem várias técnicas com os respetivos aparatos tecnológicos que podem ser utilizados para a monitorização de parâmetros para a realização da manutenção preditiva. De todas elas a monitorização de vibrações é, por norma, a componente principal desta prática, contudo não fornece todos os dados para uma manutenção preditiva eficiente (Alexandre & Rebelo, n.d.).

São os seguintes, os parâmetros ou variáveis utilizados:

- Temperatura:

A medição e controlo de temperatura dos componentes dos equipamentos é um dos parâmetros que deve ser incluído em qualquer plano de manutenção preditivo. Este ponto estará a monitorizar variações de temperatura por forma a que sejam atuados os mecanismos de paragem do equipamento aquando de um crescimento de temperatura e consoante os parâmetros previamente definidos. Os melhores resultados são realizados quando a medição é realizada continuamente (Bento et al., n.d.).

Para monitorização deste ponto, podemos recorrer a termómetros infravermelhos, scanners de linha e imagens infravermelhas (Alexandre & Rebelo, n.d.).

- Óleos lubrificantes

Esta técnica consiste na análise do estado dos óleos lubrificantes, esta pode identificar aditivos e contaminantes presentes. Permite assim identificar padrões de desgaste dos componentes e fornecer informação sobre possíveis falhas funcionais.

- Ruídos

Apesar de ser um dos parâmetros passíveis de analisar, torna-se, no entanto, difícil de o aplicar, pois em ambiente industrial todo o ruído em volta do equipamento dificulta a sua análise.

- Pressão

Prática de controlo de pressão de fluidos, é uma monitorização importante e adequada para circuitos de lubrificação/refrigeração que identifiquem altos ou baixos de pressão.

- Ensaaios não destrutivos

Estes tipos de ensaios, entre eles ensaios ultrassónicos, radiográficos, partículas magnéticas, correntes parasitas e líquidos penetrantes, são ferramentas fundamentais na avaliação de itens sujeitos a manutenção. São utilizados com a finalidade de se evitar que peças vitais em serviço entrem em colapso, causando a paralisação dos serviços, perdas de vidas humanas e de património. As inspeções periódicas são realizadas com o intuito de se detectar anomalias devido ao tempo de serviço, tais como: fissuras, corrosão, desgaste, empenos, trincas de fadiga e outros (Bento et al., n.d.).

2.5.1. DESAFIOS DA MANUTENÇÃO PREDITIVA

Os principais desafios da manutenção preditiva são:

- Qualidade dos dados

Um dos desafios encontrados na deteção de anomalias está relacionado com o comportamento anormal de dados. Enquanto uma anomalia causada por um mau funcionamento ou degradação de uma máquina contém informação valiosa, as anomalias causadas por um mau funcionamento de um sensor, bateria fraca ou outra perturbação externa, são consideradas ruído e podem causar erros de interpretação (Nunes et al., 2023).

- Custos das infraestruturas

Os custos de investimento com as infraestruturas necessárias para a elevada quantidade de dados a armazenar assim como o respetivo processamento, faz com que pequenas e médias empresas tenham dificuldade na implementação por falta de recursos (Saran et al., 2024).

- Segurança e privacidade dos dados

A segurança e a privacidade dos dados são preocupações cruciais na aplicação da IA na manutenção industrial, inclusive a partilha de informação entre diferentes equipamentos de marcas distintas. Medidas físicas e lógicas de segurança devem ser utilizadas para proteção dos dados confidenciais das empresas pois a exposição de dados sensíveis pode levar a violações de segurança e comprometer a integridade dos sistemas (Saran et al., 2024).

2.5.2. INTELIGÊNCIA ARTIFICIAL

A inteligência artificial é a atribuição de competências a computadores para a realização de tarefas que no passado apenas poderiam ser realizadas por humanos.

Nos últimos anos tem-se acompanhado um enorme desenvolvimento da IA, que vem alterando o estilo de vida das pessoas. Além desta alteração, tem-se verificado que a IA tornou-se uma importante estratégia de desenvolvimento para países em todo o mundo, aumentando a competitividade nacional e mantendo a segurança (C. Zhang & Lu, 2021).

2.5.2.1. CONCEITOS E TÉCNICAS DE APRENDIZAGEM

A aprendizagem automática é uma área de Inteligência artificial que permite que computadores aprendam e melhorem seu desempenho através de um conjunto de dados. São os seguintes alguns dos exemplos:

Inteligência artificial e aprendizagem automática (*machine learning*) - Este primeiro conceito relaciona-se com o facto do sistema ou máquina ter o objetivo de imitar a inteligência humana. Realizará uma função específica e otimizará a sua performance em função dos dados recolhidos. A aprendizagem alcançará os objetivos desejados através dos dados alcançados e será possível à máquina, através deste tipo de aprendizagem, reconhecer e reagir no futuro em função das estratégias aprendidas (Hermitaño Castro, 2022).

Aprendizagem supervisionada – A este conceito está associado a atribuição de rótulos/variáveis a fim de treinar o algoritmo para a realização de previsões, classificações e resoluções de problemas. Aqui o algoritmo está apto para identificar padrões de utilização por parte do utilizador e seleção dos rótulos/variáveis (Hermitaño Castro, 2022).

Aprendizagem não supervisionada – Ao contrário do que ocorre na abordagem supervisionada, aqui as máquinas exploram dados não rotulados ou que não foram atribuídas nenhuma variáveis. Assim, e como o algoritmo não treinado e não existem dados rotulados disponíveis, o principal foco é resolver problemas de «clustering», deteção de valores atípicos, redução de dimensionalidade e deteção de anomalias (Hermitaño Castro, 2022).

Aprendizagem profunda (*deep learning*) – Já a aprendizagem profunda, ou *deep learning*, está inserida no tipo automática, tem um estudo muito amplo devido à sua complexidade como se de uma caixa negra se tratasse que extrai representações de diferentes camadas de características (Hermitaño Castro, 2022).

Aprendizagem por reforço - Aqui são usados algoritmos que aprendem com os resultados e decidem qual ação será executada em seguida. Após cada ação, o algoritmo recebe comentários que o ajudam a determinar se a escolha feita foi correta, neutra ou incorreta. É uma boa técnica aplicada em sistemas automatizados que precisam tomar muitas decisões simples sem diretrizes humanas (Azure Microsoft, n.d.).

2.5.3. IMPACTO DA IA NA MANUTENÇÃO PREDITIVA

Como já foi descrito, a eficiência industrial é crucial no ambiente empresarial pois procura reduzir custos e aumentar a produtividade impactando diretamente no crescimento das empresas.

Desta forma a IA aplicada à manutenção industrial proporciona elevados benefícios, oferecendo às empresas capacidades de otimizar operações e maximizarem a eficiência e capacidade dos seus equipamentos (Saran et al., 2024).

Os benefícios da aplicação de IA na manutenção industrial incluem:

- Optimização de processos

Os algoritmos de IA podem analisar de forma contínua grandes quantidades de dados, proporcionando tomadas de decisão mais precisas com otimização da gestão e dos processos industriais. Além disso a IA é capaz de garantir que as operações ocorram de maneira otimizada e com mínimos de desperdício.

- Diagnóstico de falhas

Dotam os softwares que a utilizam de mecanismos de deteção de falhas em equipamentos e plantas industriais em tempo real pela sua capacidade de gestão de grande capacidade de dados, reduzindo o tempo de inatividade ao agilizar respostas a falhas, como também contribui para a longevidade dos equipamentos, ao garantir que intervenções de manutenção sejam realizadas de maneira oportuna e eficiente.

- Planeamento de manutenção

Com a capacidade de analisar históricos e condições operacionais, colabora no planeamento de manutenções, incluindo a programação de inspeções e substituições de peças de acordo com a probabilidade de falha. Contribuindo assim para uma gestão mais eficiente dos recursos e identificando as condições e o desempenho real dos equipamentos (Saran et al., 2024).

2.6. APRENDIZAGEM AUTOMÁTICA

A aprendizagem automática é uma das tecnologias mais revolucionária no campo de IA. Teve um crescimento de popularidade nos últimos anos pela capacidade de realizar previsões com base em grandes quantidades de dados, que anteriormente era impossível de obter (Sharifani & Amini, n.d).

Esta tecnologia envolve a utilização de algoritmos para aprender com os dados, com o objetivo de melhorar a precisão e a eficiência das previsões ou decisões. A aprendizagem

automática envolve normalmente a utilização de métodos estatísticos para aprender com os dados (Sharifani & Amini, n.d.).

A aprendizagem automática é um componente essencial da Indústria 4.0, especialmente na área da manutenção preditiva. A aplicação de algoritmos de aprendizagem automática a dados extraídos de sensores, máquinas ou sistemas permite a realização de uma série de tarefas, incluindo a classificação de falhas e a previsão de avarias dentro de um prazo específico. Isto aumenta a eficácia das operações de manutenção (Paredes et al., 2025).

2.6.1. ALGORITMOS DE APRENDIZAGEM AUTOMÁTICA

Estão atualmente disponíveis distintos algoritmos de aprendizagem automática que ajudam na exploração e análise de conjuntos de dados complexos de forma a ver sentido neles. Estes algoritmos enquadram-se consoante a técnica de aprendizagem de máquina. Com a aplicação e o respetivo estudo dos algoritmos encontraremos o que melhores performances e resultados obtém para o *dataset* que pretendemos avaliar (Azure Microsoft, n.d.). Seguidamente são apresentados alguns algoritmos.

Regressão logística

Trata-se de um tipo popular de análise de regressão do tipo supervisionado que se utiliza quando o objetivo é obter respostas de tipo “Sim” ou “Não” com dados binários (Emeritus Enterprise, 2023).

Este é um método estatístico utilizado em tarefas de classificação. Ele é capaz de prever resultados através da modelação entre as características de entrada e a variável do alvo (Hossein Baradaran, n.d.).

Num algoritmo de regressão logística, temos uma curva continua em forma de “S” como apresentado na Figura 3.




Figura 3 - Gráfico de Regressão Logística(Raquel Araújo, 2022)

Árvores de Decisão

As árvores de decisão são algoritmos de aprendizagem automática utilizados tanto para tarefas de classificação como de regressão ainda do tipo supervisionado. São constituídas por nós, ramos e folhas, sendo que os nós são as características dos dados, os ramos representam as decisões baseadas nessas características e as folhas (nós terminais) representam o resultado previsto ou a etiqueta da classe. Com base no valor de uma característica escolhida que melhor separa os dados em classes ou grupos distintos, o algoritmo vai dividindo recursivamente os dados em subconjuntos (Santos, 2022).

A solução do problema é dada em forma de árvore que combina soluções de subproblemas mais simples Figura 4.




Figura 4 - Estrutura de Árvore de Decisão (Fonte: Autor)

Floresta Aleatória (*Random Forest*)

Este é um método que utiliza árvores de decisão como base de aprendizagem Figura 5, foi desenvolvido tendo em vista a melhoria do desempenho preditivo e a sua robustez. Este algoritmo combina os resultados de várias arvores, onde cada arvore é treinada num subconjunto bootstrapped, isto é, os subconjuntos são criados a partir de um conjunto de dados original, onde os mesmos elementos podem aparecer várias vezes. Esta abordagem assegura a diversidade entre as arvores, melhorando o desempenho global. O algoritmo é altamente eficaz quando aplicado a um conjunto de dados complexo, incluído aqueles com relações não lineares (Hossein Baradaran, n.d.).

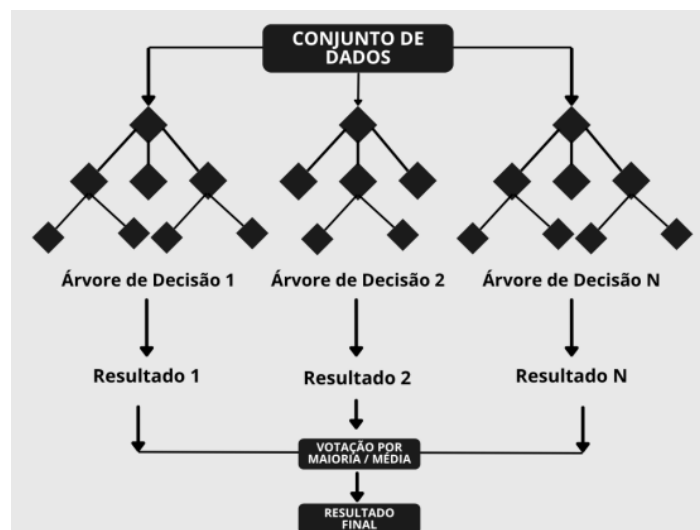


Figura 5 - Diagrama do funcionamento da Floresta Aleatória (GOMES TELES, 2025)

Gradient Boosting

O Gradiente Boosting Figura 6 é uma poderosa técnica de aprendizagem de conjunto que melhora o desempenho dos modelos de aprendizagem mais fracos, normalmente árvores de decisão. O seu funcionamento é através da construção sequencial de modelos, em que cada novo modelo se foca em corrigir os erros dos seus anteriores. O processo é repetido iterativamente, minimizando uma função de perda escolhida até que o nível de precisão desejado seja alcançado (Hossein Baradaran, n.d.).

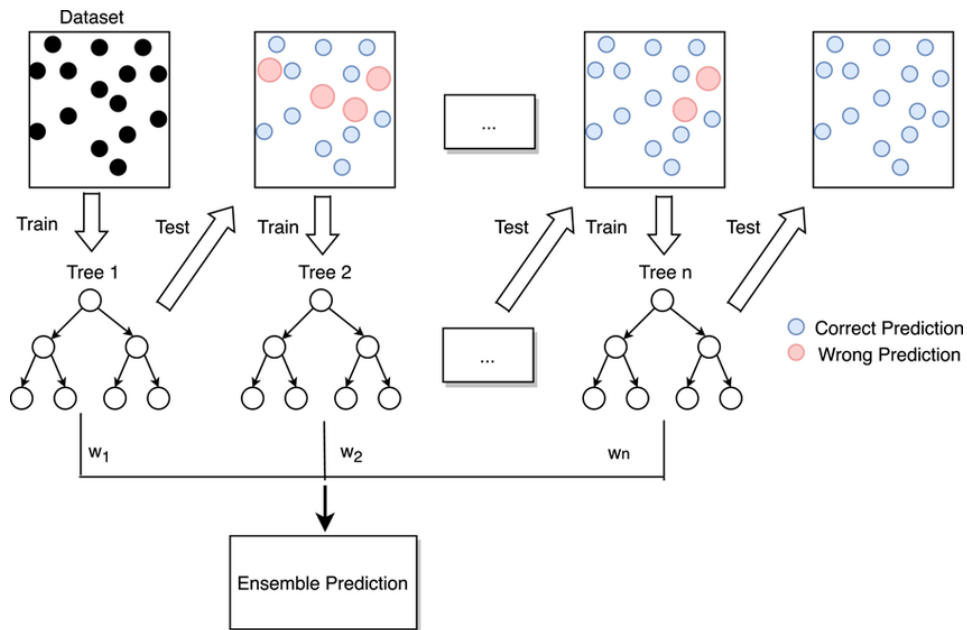


Figura 6 - Diagrama de Fluxo do método Gradient Boost (T. Zhang et al., 2021)

Redes Neurais

Trata-se de um modelo de aprendizagem automática inspirada na estrutura e função do cérebro humano (Figura 7). É composto por um conjunto de nós de processamento (chamados neurónios artificiais) que estão interligados entre si, em que cada camada de nós desempenha uma função específica no processo de aprendizagem, e que trabalham em conjunto para aprender com os dados e fazer previsões ou tomar decisões. O princípio de funcionamento é inspirado no funcionamento dos neurónios biológicos (Santos, 2022).




Figura 7 – Diagrama de Fluxo de uma Rede Neuronal (Santos, 2022)

3. DESENVOLVIMENTO

No âmbito dos desafios cada vez mais rigorosos apresentados pela indústria, torna-se importante que os processos sejam sempre contínuos, em que falhas ou paragens sejam inexistentes, pouco frequentes ou de tempos muito baixos.

Para isso os equipamentos necessitam ser monitorados e as respetivas manutenções ou paragens realizadas de forma rápida, eficiente e programada. Contribuirá para isso a adoção da análise preditiva, pois tem a capacidade de identificar, detetar ou prever em cada intervenção possíveis anomalias e falhas que possam ocorrer, focando-se apenas na correção antecipada de eventuais problemas.

Existem dados que nos mostram um antes e um após a análise preditiva bastante relevante, como ilustra a Figura 8. Aqui é possível verificar as melhorias apresentadas pela aplicação de métodos de MP, são alguns exemplos o aumento de tempo de produção, aumento do tempo entre falhas, diminuição das paragens por emergência, entre outros. Fazer, no entanto, menção ao incremento brutal de eficiência de entregas a tempo de 83% para 97% e uma eficácia geral de 68% para 89%.

Métrica de Desempenho	Antes da Análise Preditiva	Após a implementação da Análise Preditiva	Melhoria
Tempo de inatividade não planeado	18% do tempo de produção	12,6% do tempo de produção	30% de redução
Confiabilidade do Equipamento (MTBF)	52 dias	96 dias	85% de melhoria
Manutenção de emergência	65% das atividades	27% das atividades	Redução de 58%
Custo de manutenção por unidade	US\$ 12,50/tonelada	US\$ 7,80/tonelada	Redução de 38%
Taxa de entrega pontual	83%	97%	Melhoria de 17%
Eficácia geral do equipamento	68%	89%	Melhoria de 31%
Adoção de Manutenção Preditiva	0%	78%	Transformação completa
Incidentes de segurança	15/ano	4/ano	Redução de 73%

Figura 8 – Métricas de desempenho após implementação de análise Preditiva, adaptado de (Bennett, 2025)

3.1. METODOLOGIA

Para o desenvolvimento e apresentação do trabalho, será seguida a metodologia CRISP-DM, ilustrada na Figura 9. Esta metodologia é muito utilizada na exploração de dados, e conta com 6 fases interativas, entre elas (Schröer et al., 2021):

- **Compreensão do negócio:**

Aqui será abordado o problema a estudar e a exploração dos dados, classificando-os e criando um plano.

- **Compreensão dos dados:**

Nesta fase é importante descrever os dados assim como verificar a qualidade dos mesmos.

- **Preparação dos dados:**

Definição dos critérios e respetiva definição para a seleção dos dados que se utilizarão, aqui serão ser limpos os dados de má qualidade.

- **Modelagem:**

Consiste na seleção da técnica de modelação, construir o caso e o modelo. Aqui são definidos os parâmetros específicos para a avaliação.

- **Avaliação:**

Interpretação e comparação de resultados para definição de novas ações se necessárias.

- **Implementação:**

A última fase do processo é o planeamento da implementação, monitorização e manutenção.




Figura 9 – 6 etapas do CRISP-DM (Lima, 2020)

3.2. ANÁLISE DO PROBLEMA

Quanto à análise do nosso problema, estudaremos de que forma os algoritmos de análise preditiva nos auxiliam na detecção de falhas, utilizando para essa finalidade um Dataset recorrendo à plataforma Kaggle¹, onde foram medidos no decorrer do seu funcionamento variáveis como a temperatura, torque, rotação, velocidade.

Estas variáveis foram medidas em tempo real, e sempre que uma falha ocorria era atribuído “0” ou “1”.

Assim sendo o objetivo de análise para este problema, era compreender com base nos dados recolhidos qual o algoritmo que aplicado ao nosso modelo apresentaria maior precisão e capacidade de detecção de falha, de forma a ser implementado em ambiente real e assim prever futuras falhas e conseqüentemente acionar a manutenção respetiva.

¹ <https://www.kaggle.com/code/carlkirstein/predictive-maintenance-milling-multiclass-99-4>

3.3. COMPREENSÃO E PREPARAÇÃO DOS DADOS

Para este trabalho foi utilizado um conjunto de dados sintéticos obtidos a partir de uma fresadora. Este consiste em 10 000 pontos de dados armazenados em linhas com 14 colunas. Das 14 colunas constituintes utilizamos 7, sendo uma delas o valor target em “0” e “1” correspondente à falha ou não falha.

Ao dataset original foram deduzidas algumas variáveis que se encontravam sem valor e que não iríamos necessitar para a avaliação, ficando apenas com as variáveis X.2, X.3, X.4, X.5, X.6, X.7 e X.8, conforme Figura 10, que representam respetivamente a tipologia da máquina, temperatura do ar, temperatura do processo, velocidade de rotação, força, desgaste da ferramenta e falha da máquina.

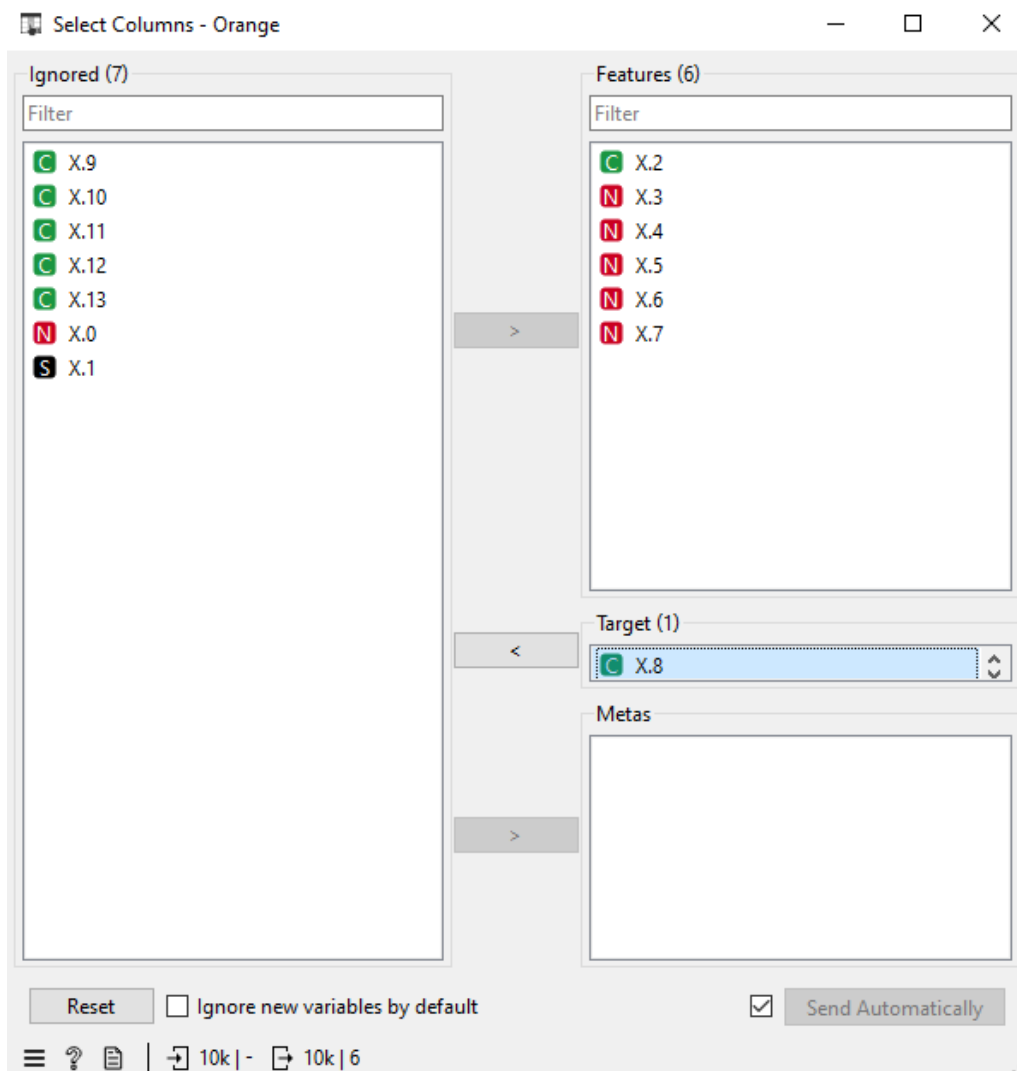


Figura 10 – Seleção de variáveis do Dataset

Ainda na preparação das variáveis, de um total de 10000 registos do nosso Dataset, utilizamos a divisão 80/20, como na Figura 11, em que 80% dos valores seriam utilizados para o modelo, enquanto os restantes 20% seriam utilizados pelo algoritmo para a validação e testes do modelo.

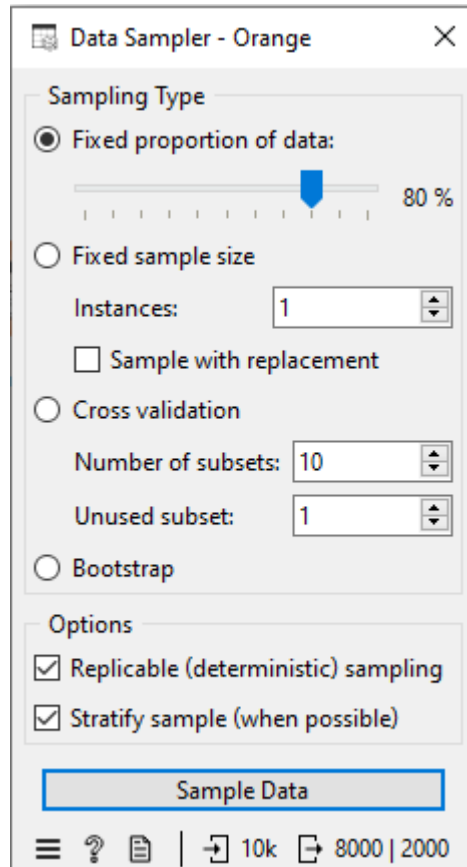


Figura 11 – Divisão do Dataset em 80/20

3.4. MODELAÇÃO DO PROBLEMA

O problema foi modelado na ferramenta Orange², utilizando 5 algoritmos de aprendizagem automática com a finalidade de conhecer qual o algoritmo que apresenta melhor desempenho (Figura 12).

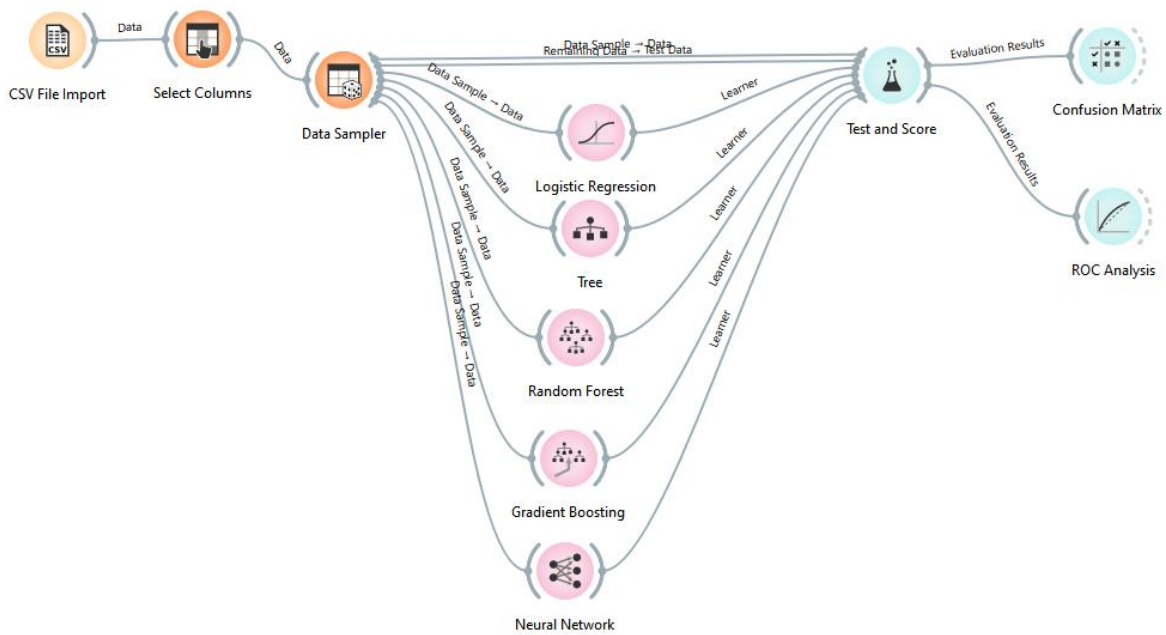


Figura 12 – Modelo aplicado no Orange

Em todos os algoritmos aplicados foram utilizadas as configurações standards dos mesmos, não havendo alterações às predefinições iniciais. Seguem apresentadas as características de treino do algoritmo.

² <http://orangedatamining.com>

Logistic Regression

No algoritmo do *Logistic Regression*, conforme foi comentado anteriormente, os parâmetros utilizados foram os predefinidos e apresentados na Figura 13. O tipo de regularização utilizado foi Regularização L2, ou “*Ridge regression*”, este penaliza os coeficientes grandes ao somar o quadrado dos coeficientes ao termo de custo. O parâmetro “C”, como é igual a “1” trata-se de um fator padrão de força média.

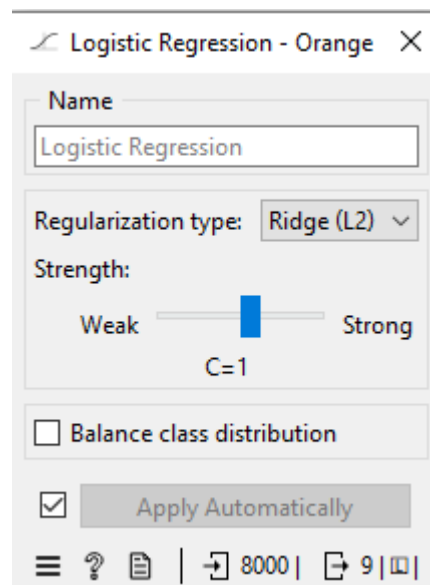


Figura 13 – Parâmetros do algoritmo *Logistic Regression*

Tree

Relativamente aos parâmetros aplicados no algoritmo *tree*, Figura 14, com a seleção do “*Induce binary tree*” definimos que a árvore será binária, ou seja, cada nó terá no máximo dois ramos. Com a inclusão do parâmetro “*Min. number of instances in leaves*” e “*Do not split subsets smaller than*”, definimos o número mínimo de exemplos que um nó folha pode conter, ajudando a prevenir o *overlifting* pela não permissão de criar folhas com pouquíssimos dados e que subconjuntos com menos de 5 exemplos não sejam divididos, fazendo com que haja uma paragem antecipada e assim evitar partições de dados irrelevantes ou ruidosos.

Por fim com “*Limit the maximal tree depth to*” definimos a profundidade da árvore permitindo árvores mais profundas, mas que pode levar ao *overlifting*, enquanto com o “*Stop when majority reaches*” forçamos a árvore a parar de dividir um nó se 95% ou mais dos exemplos do nó forem da mesma classe.

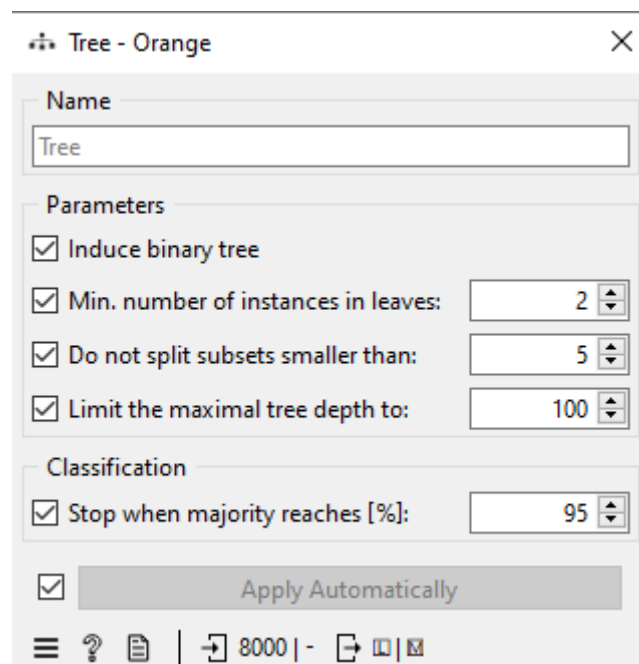


Figura 14 – Parâmetros do algoritmo *Tree*

Random Forest

Nos parâmetros básicos do *Random Forest*, e como se pode consultar na Figura 15 em “*Number of trees*”, ficou definido o número de árvores que o algoritmo podia ter, neste caso o valor predefinido foram 10, e foi o utilizado. O outro parâmetro selecionado foi o “*Do not split subsets smaller than*”, este responsável por definir que subconjuntos com menos de 5 exemplos não seria dividido.

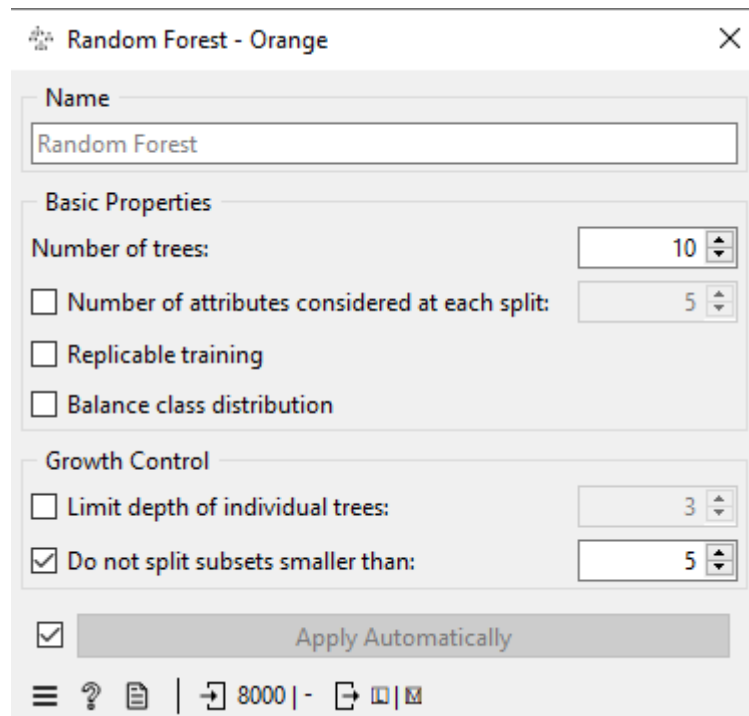


Figura 15 – Parâmetros do algoritmo *Random Forest*

Gradient Boosting

Já na representação do *Gradient Boosting* da Figura 16, nas propriedades básicas definimos como 100 o número de árvores e um *Learning Rate* de 0,3, este valor apresenta a taxa de aprendizagem do algoritmo. Ainda nos básicos, acionamos o “*Replicable training*”, que nos assegura que o modelo é repetível, ou seja, executar o mesmo processo e obter os mesmos resultados.

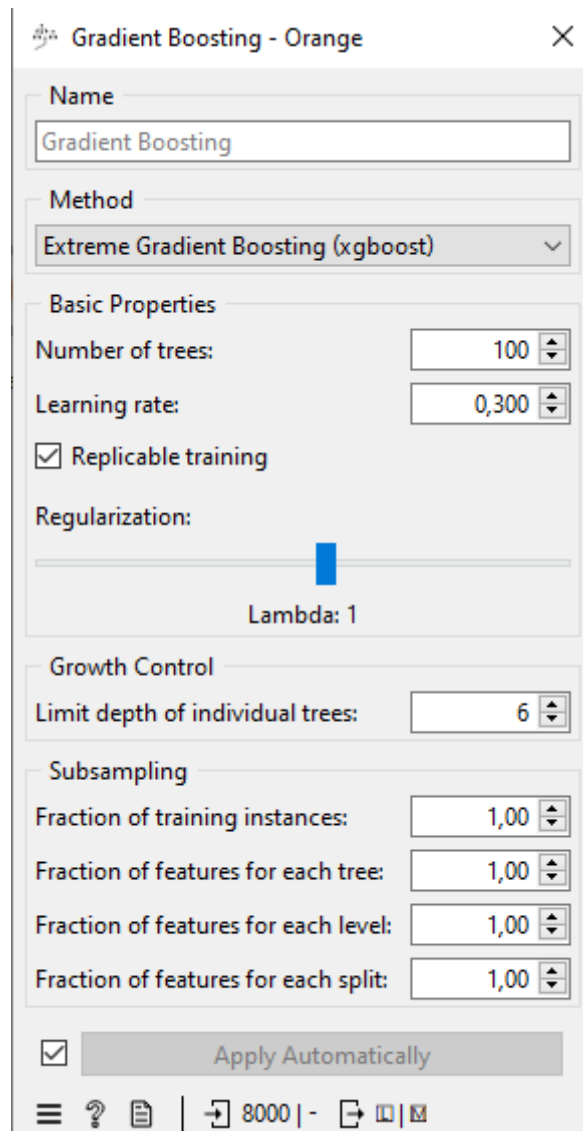


Figura 16 – Parâmetros *Gradient Boosting*

O parâmetro de regularização é do tipo L2 “*Ridge regression*”, com lambda 1. A definição deste parâmetro penaliza a complexidade do modelo, mas ajuda a evitar o *overfitting* e o

peso das árvores. Em seguida definimos a profundidade de cada árvore em 6. Por fim no “*subsampling*”, e com a utilização de todos os valores em 1 ou 100%, indica-nos que não estamos a utilizar dados de forma aleatória, isto é, as árvores são treinadas com todos os dados e com todas as características a cada passo, aumentando o risco de *overfitting* e diminuindo a diversidade no conjunto.

Neural Network

Por último no algoritmo de “*Neural Network*” Figura 17, utilizamos uma camada oculta de 100 neurónios, Ativação ReLU, Otimizador Ada, Regularização leve ($\alpha = 0.0001$), um máximo de 200 iterações e treino replicável, que garante que os resultados do treino sejam reproduzíveis ao usares sempre o mesmo “*random seed*”.

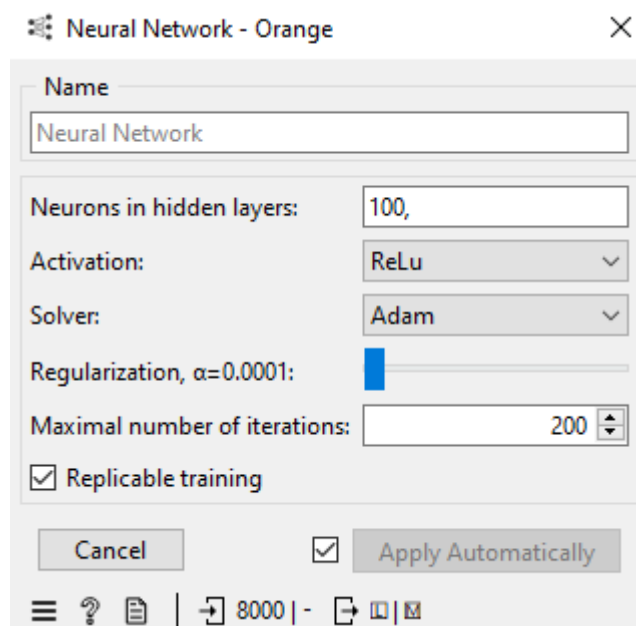


Figura 17 – Parâmetros Neural Network

Para verificação dos resultados foram aplicadas as seguintes métricas, além da posterior análise das respetivas matrizes de confusão de cada algoritmo (Maior & Neto, 2021):

Precision: Obtida pela razão entre verdadeiros positivos (valores classificados de forma correta pelo algoritmo como positivos) e a soma destes verdadeiros positivos e falsos positivos (os valores classificados como positivos de forma incorreta);

$$P = \frac{TP}{TP + FP}$$

Recall (Sensibilidade): É determinada pela divisão de verdadeiros positivos (valores classificados corretamente como positivos) pela soma de verdadeiros positivos e falsos negativos (valores classificados incorretamente pelo algoritmo como falsos);

$$Recall = \frac{TP}{TP + FN}$$

F1-score: Esta métrica mede a exatidão dos resultados, é obtida a partir da média harmônica entre a *precision* e *recall*, em que quanto maior o valor desta média maior a exatidão dos resultados. É especialmente útil em cenários de classes não balanceadas.

$$F1 - score = 2x \left[\frac{(precision \times recall)}{(precision + recall)} \right]$$

3.5. AVALIAÇÃO

O estudo incidiu na aplicação de alguns algoritmos ao nosso modelo. Desta forma foi possível estudar os algoritmos de *logistic regression*, *tree*, *random forest*, *gradient boosting*, e *neural network* e assim conseguir verificar a performance de cada um no modelo.

Com a finalidade de conhecer a performance de cada algoritmo e analisar o equilíbrio entre falsos positivos e falsos negativos, foram avaliados os resultados obtidos na *precision*, *recall* e *F1-score*.

A Figura 18, apresenta a performance dos vários algoritmos.

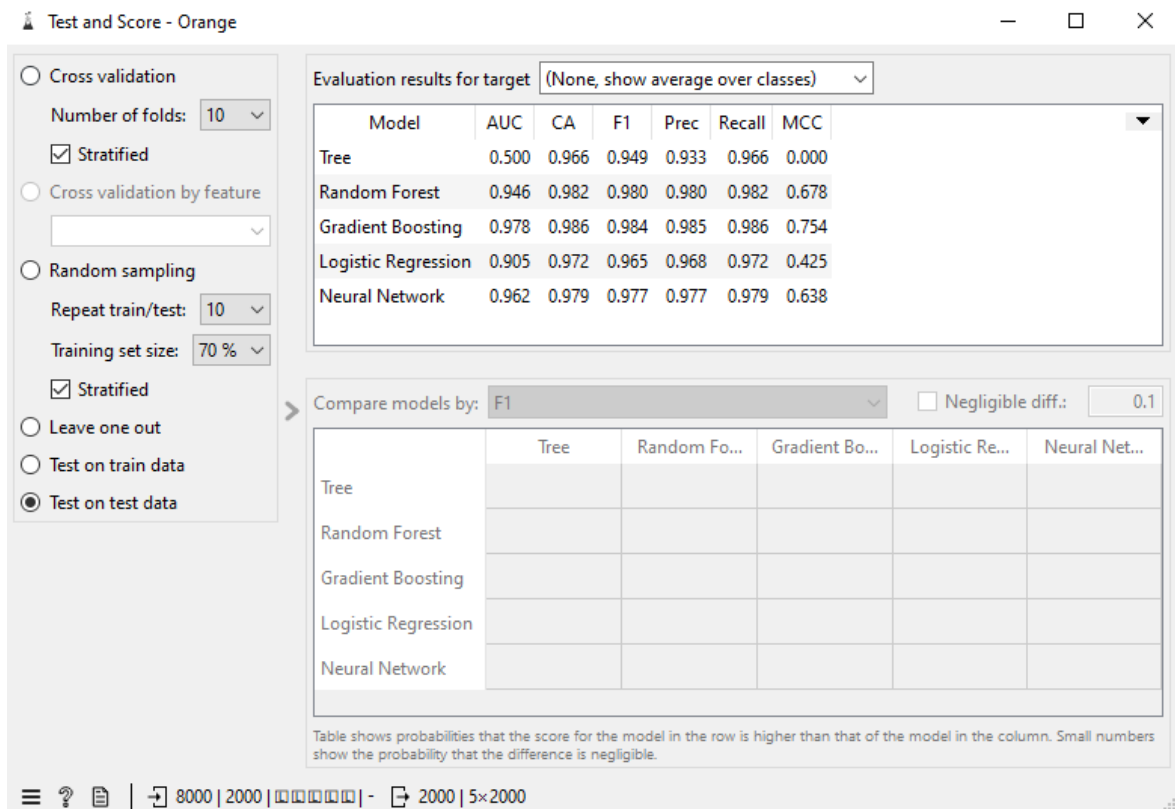


Figura 18 - Desempenho dos algoritmos

Da perspectiva da Precisão (Figura 19), podemos observar que, ainda que com uma percentagem elevada, o algoritmo de *Tree* é o que apresenta performance mais baixa, com um valor de 0,933. No outro extremo, e com uma percentagem de 0,986 de performance temos o *Gradient Boosting*. Desta forma e a nível de precisão podemos observar que o algoritmo de *Gradient Boosting* é o que nos oferece maior precisão quando aplicado ao nosso modelo.

Model	AUC	CA	F1	Prec	Recall	MCC
Tree	0.500	0.966	0.949	0.933	0.966	0.000
Random Forest	0.929	0.980	0.977	0.977	0.980	0.641
Gradient Boosting	0.978	0.986	0.984	0.985	0.986	0.754
Logistic Regression	0.905	0.972	0.965	0.968	0.972	0.425
Neural Network	0.962	0.979	0.977	0.977	0.979	0.638

Figura 19 - Análise dos algoritmos ao nível da Precisão

De seguida, e analisando a segunda métrica definida, o *Recall* (Figura 20), constatamos que tal como aconteceu com a outra métrica, aqui novamente o algoritmo *Tree* apresenta o valor mais baixo de performance com 0,966. De igual forma o *Gradient Boosting* foi o modelo que mais que mais confiança apresentou com 0,986.

Model	AUC	CA	F1	Prec	Recall	MCC
Tree	0.500	0.966	0.949	0.933	0.966	0.000
Random Forest	0.929	0.980	0.977	0.977	0.980	0.641
Gradient Boosting	0.978	0.986	0.984	0.985	0.986	0.754
Logistic Regression	0.905	0.972	0.965	0.968	0.972	0.425
Neural Network	0.962	0.979	0.977	0.977	0.979	0.638

Figura 20 – Análise dos algoritmos ao nível do *recall*

Por último, avaliamos o F1-score (Figura 21). Novamente aqui observamos que o algoritmo *Tree* apresenta a performance mais baixa, com 0,949, enquanto no outro extremo voltamos a ter o *Gradient Boosting* como o algoritmo que nos mostra a métrica mais alta com 0,986.

Model	AUC	CA	F1	Prec	Recall	MCC
Tree	0.500	0.966	0.949	0.933	0.966	0.000
Random Forest	0.929	0.980	0.977	0.977	0.980	0.641
Gradient Boosting	0.978	0.986	0.984	0.985	0.986	0.754
Logistic Regression	0.905	0.972	0.965	0.968	0.972	0.425
Neural Network	0.962	0.979	0.977	0.977	0.979	0.638

Figura 21 – Análise dos algoritmos ao nível do F1-score

Em revisão geral das métricas avaliadas, podemos observar que o *Gradient Boosting* é o que apresenta melhor desempenho global. Estes valores obtidos indicam que o modelo consegue capturar praticamente todos os casos positivos (alto *recall*) sem comprometer a precisão das suas previsões. Além disso, o facto de apresentar um o F1-score elevado

demonstra um ótimo equilíbrio entre estas duas métricas, podendo-o considerar altamente confiável para aplicações críticas.

Apesar de *Gradient Boosting* ser o que apresenta melhor resultado, também o *Random Forest* e a *Neural Network* apresentam desempenhos muito consistentes.

Referir por fim que o modelo que apresenta pior resultado é o modelo *Tree*, a baixa precisão indica um número considerável de falsos positivos, o que reduz a utilidade deste modelo.

Analisando a curva ROC representada na Figura 22, observa-se a relação da taxa dos verdadeiros positivos e os falsos positivos dos 5 modelos estudados.

Com a cor roxa a curva referente ao *Gradient Boosting*, a verde-claro a *Neural Network*, laranja a *Random Forest*, a cor-de-rosa a *Logistic Regression* e a verde a *Tree*.




Figura 22 - Curva ROC

Da representação do gráfico da Figura 22, podemos argumentar que a curva referente ao modelo de *Gradient Boosting* acima das demais, aproximando-se do canto superior esquerdo do gráfico, onde a taxa de verdadeiros positivos aproximasse mais do “1”

enquanto os falsos positivos sempre muito perto do “0”. Isto é, este modelo demonstra a melhor capacidade discriminativa, indicando uma elevada taxa de verdadeiros positivos e uma baixa taxa de falsos positivos ao longo de vários limiares.

Também da representação concluímos que tanto o modelo *Random Forest* como o *Neural Network*, apresentam as suas curvas perto do ideal, ao contrário do modelo *Logistic Regression* e de *Tree*, ambos afastados do ideal, estando o modelo *Tree* bastante longe do ideal, considerando que tem um comportamento instável e aleatório.

Por fim, a análise das matrizes confusão referente a cada modelo, onde podemos ver a taxa de acerto de cada modelo (Figuras 23 a 27). Também com esta análise se pode concluir qual o modelo com melhor performance.

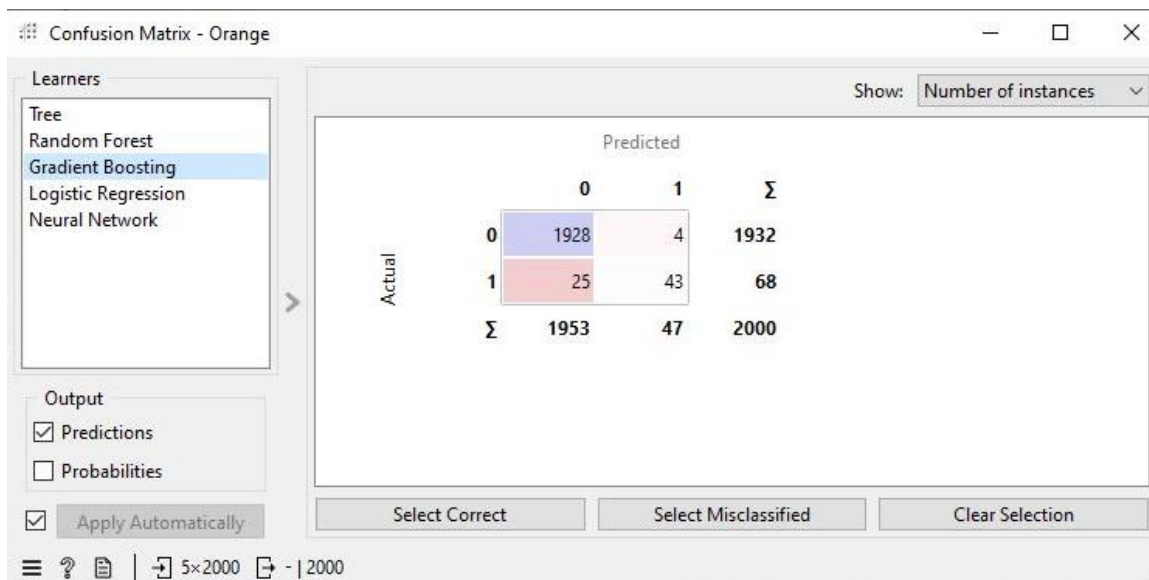


Figura 23 - Matriz Confusão *Gradient Boosting*

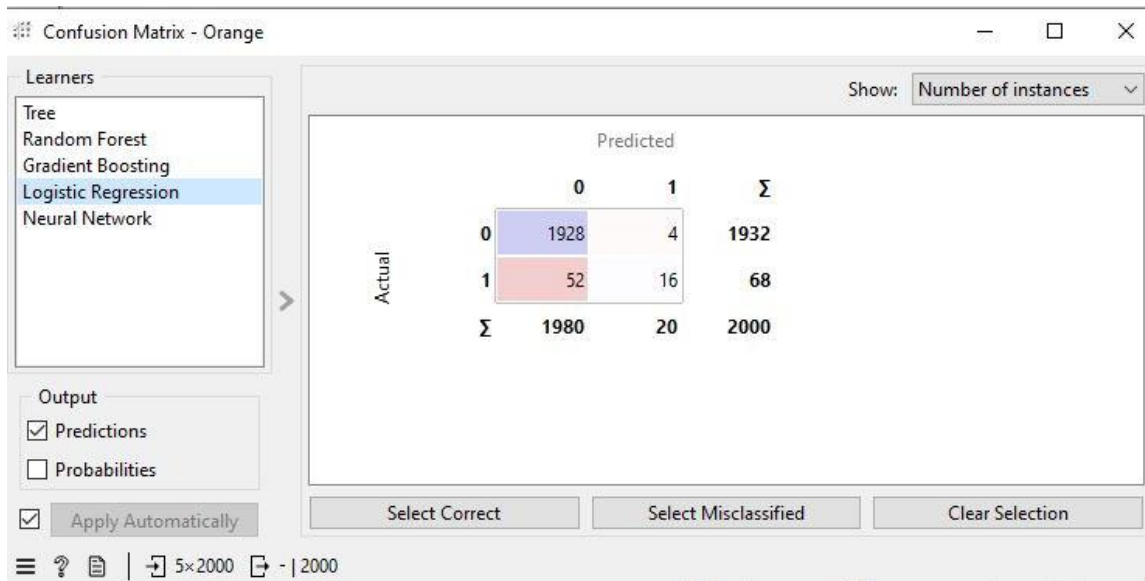


Figura 24 – Matriz confusão *Logistic Regression*

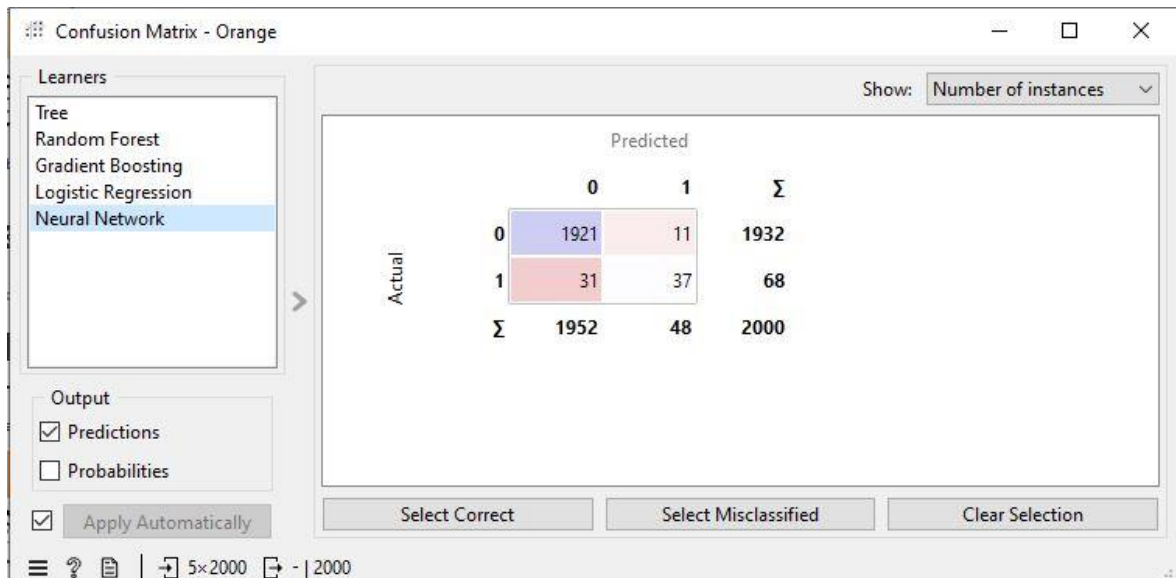


Figura 25 – Matriz confusão *Neural Network*

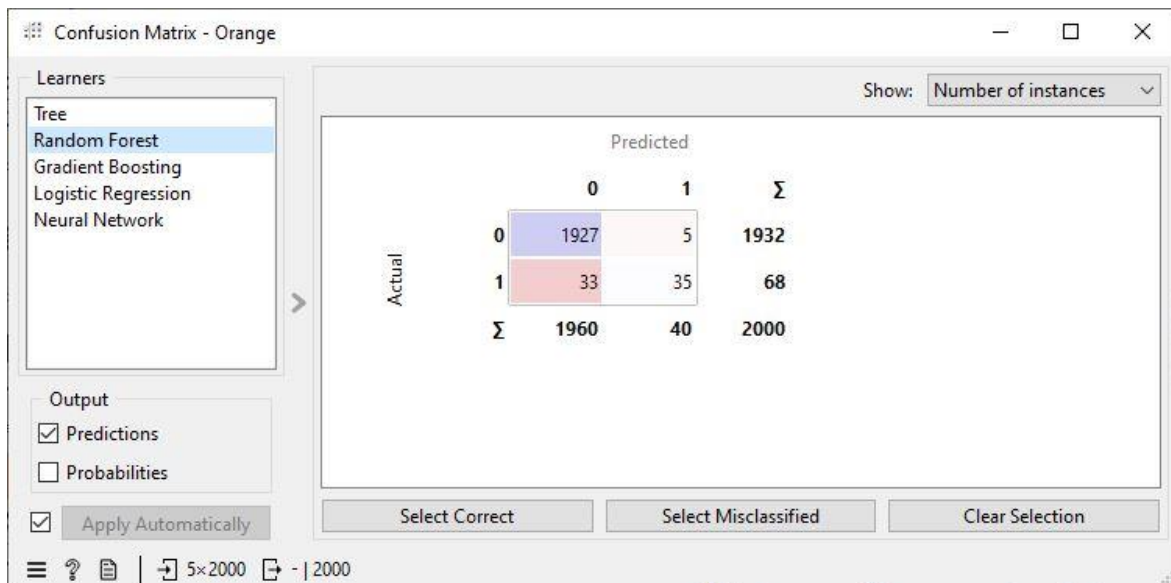


Figura 26 -Matriz confusão *Random Forest*

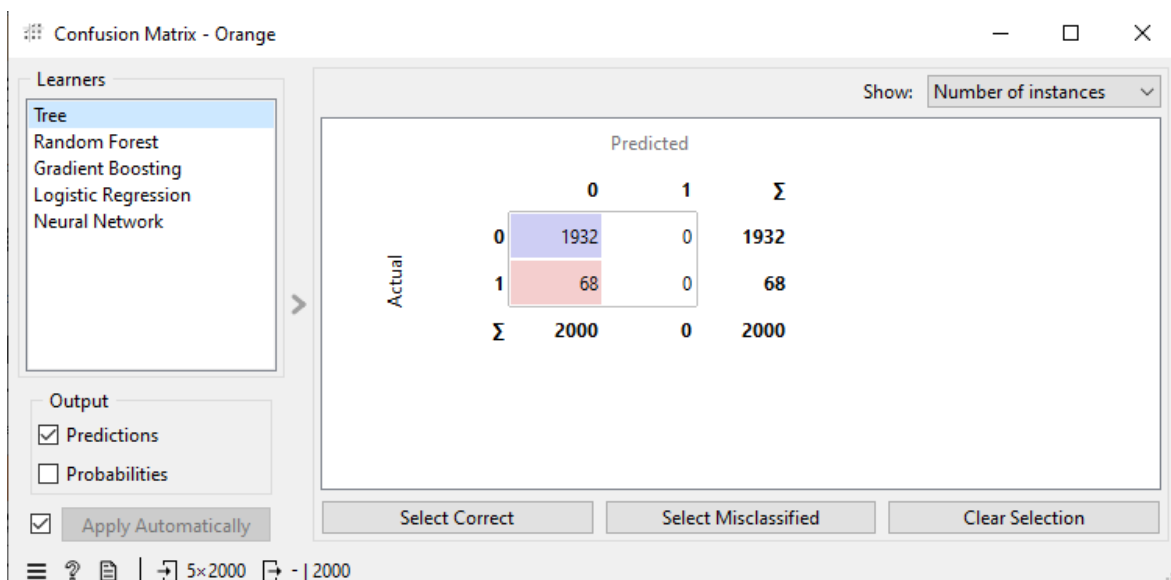


Figura 27 – Matriz confusão *Tree*

A diagonal principal, (0-0;1-1) das matrizes confusão, representam previsões corretas do modelo, ou seja, o número de instâncias em que o que acontece coincide com a previsão do modelo (Guedes et al., 2024).

Pela avaliação da matriz confusão, podemos observar que a classe zero tem uma classificação bastante boa, algo que já não acontece na classe 1. Isto está relacionado com o não balanceamento dos dados, pois como podemos observar os alvos de treino presentes

neste Dataset tem uma predominância de não falhas “0” comparativamente com as falhas “1”, desta forma não podemos treinar tão bem o algoritmo para os casos em que há falhas do sistema.

4. CONCLUSÕES

Este trabalho foi desenvolvido no âmbito do estudo da Manutenção Preditiva de forma a compreender de que modo esta abordagem na indústria ajuda melhorar os processos produtivos.

Esta área que vem sendo aplicado um pouco por toda a indústria, incluindo começando-se a abordar esta temática e a respetiva implementação pelos fabricantes de equipamentos dos próprios sistemas de previsão de falhas.

Neste trabalho, apesar de os dados não estarem balanceados por contermos mais elementos “0” que “1”, foi possível constatar que os algoritmos de aprendizagem automática se comportam de maneira diferente para as mesmas variáveis. Uns têm uma taxa de acerto elevada, neste caso o *Gradient Boosting*, enquanto outros erram demasiado, como foi o exemplo da árvore de decisão que simplesmente não acertou em possíveis falhas.

Uma das limitações encontradas neste trabalho foi como já frisado em cima o não balanceamento das variáveis do Dataset, isto não permite ao algoritmo uma aprendizagem por repetição e por consequência terá uma taxa de falhas significativa, porém foi possível encontrar um modelo melhor que todos os outros para possível implementação.

Um dos trabalhos futuros a realizar seria a implementação do algoritmo em ambiente real, para poder obter mais dados e assim por repetição, tendo mais exemplos e uma amostragem maior, poder aprender.

Referências Bibliográficas

- Achouch, M., Dimitrova, M., Ziane, K., Sattarpanah Karganroudi, S., Dhouib, R., Ibrahim, H., & Adda, M. (2022). On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. In *Applied Sciences (Switzerland)* (Vol. 12, Issue 16). MDPI. <https://doi.org/10.3390/app12168081>
- Alexandre, D., & Rebelo, M. (n.d.). *Otimização das Paragens Produtivas de uma Máquina de Injeção Através de Manutenção Preditiva*.
- Andrianandrianina Johanesa, T. V., Equeter, L., & Mahmoudi, S. A. (2024). Survey on AI Applications for Product Quality Control and Predictive Maintenance in Industry 4.0. In *Electronics (Switzerland)* (Vol. 13, Issue 5). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/electronics13050976>
- Azure Microsoft. (n.d.). *Algoritmos de aprendizado de máquina*. <https://Azure.Microsoft.Com/Pt-Br/Resources/Cloud-Computing-Dictionary/What-Are-Machine-Learning-Algorithms#layout-Container-Uidb193>.
- Bennett, T. (2025, August). *Reducing Downtime by 30 Percent with Predictive Maintenance Analytics*.
- Bento, E., Florianopolis, A., & De, A. (n.d.). *UNIVERSIDADE FEDERAL DE SANTA CATARINA PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA ESTUDO COMPARATIVO DE TÉCNICAS DE MEDIÇÃO E ANÁLISE DE VIBRAÇÕES PARA A MANUTENÇÃO PREDITIVA EM MANCAIS DE ROLAMENTOS DISSERTAÇÃO SUBMETIDA A UNIVERSIDADE FEDERAL DE SANTA CATARINA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA MECÂNICA*.
- De Souza, V. C., Marchi, C. de S., Bueno, N. V., Faustino, T. S., & Barreiro, T. A. (2022). Utilização das tecnologias da indústria 4.0 na manutenção preditiva através do monitoramento de equipamentos e instalações / Use of industry 4.0 technologies in predictive maintenance through monitoring equipment and facilities. *Brazilian Journal of Development*, 8(1), 7063–7083. <https://doi.org/10.34117/bjdv8n1-478>

Emeritus Enterprise. (2023, July 25). *Machine Learning: conheça os principais algoritmos e em quais áreas podem ser utilizados*. <https://Brasil.Emeritus.Org/Conteudo/Machine-Learning/#:~:Text=Na%20pr%C3%A1tica%2C%20trata%2Dse%20de%20submeter%20o%20sistema,Os%20acertos%20e%20penalidades%20para%20os%20erros>.

GOMES TELES, D. A. (2025). *PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS ESCOLA POLITÉCNICA E DE ARTES GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO Aplicação de Floresta Aleatória para Identificação de Fraudes em Transações Financeiras DAVI ARTHUR GOMES TELES GOIÂNIA 2025*.

Guedes, E. dos S., Oliveira, E. T. de, Albuquerque, O. de S., Sousa, A. L. de, & Melo Júnior, G. de. (2024). Comparação de algoritmos de aprendizado de máquina baseados em árvores de decisão na previsão de nível de escrita do ensino básico: estudo de caso em escolas do município de Vitória do Xingu - Pará. *Cuadernos de Educación y Desarrollo*, 16(11), e6269. <https://doi.org/10.55905/cuadv16n11-036>

Hermitaño Castro, J. A. (2022). Aplicación de Machine Learning en la Gestión de Riesgo de Crédito Financiero: Una revisión sistemática. *Interfases*, 015, 160–178. <https://doi.org/10.26439/interfases2022.n015.5898>

Hossein Baradaran, A. (n.d.). *Predictive Maintenance of Electric Motors Using Supervised Learning Models: A Comparative Analysis*.

Lima, L. O. (2020, November). *CRISP-DM – Conceitos*.

Maior, A. S., & Neto, T. (2021). *MODELO DE GESTÃO COM RECURSOS A ALGORITMOS DE MACHINE LEARNING NA INDÚSTRIA PECUÁRIA DE CORTE BOVINO*.

Molęda, M., Małysiak-Mrozek, B., Ding, W., Sunderam, V., & Mrozek, D. (2023). From Corrective to Predictive Maintenance—A Review of Maintenance Approaches for the Power Industry. In *Sensors* (Vol. 23, Issue 13). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s23135970>

- Nunes, P., Santos, J., & Rocha, E. (2023). Challenges in predictive maintenance – A review. In *CIRP Journal of Manufacturing Science and Technology* (Vol. 40, pp. 53–67). Elsevier Ltd. <https://doi.org/10.1016/j.cirpj.2022.11.004>
- Paredes, J., Chávez, D., Isa-Jara, R., & Vargas, D. (2025). A hybrid machine learning algorithm approach to predictive maintenance tasks: A comparison with machine learning algorithms. *Results in Engineering*, 26. <https://doi.org/10.1016/j.rineng.2025.105137>
- Raquel Araújo. (2022, December 5). *Regressão Logística – Algoritmos de Aprendizado de Máquinas*. <https://www.hashtagtreinamentos.com/regressao-logistica-ciencias-dados>.
- Salawu, E. Y., Awoyemi, O. O., Akerekan, O. E., Afolalu, S. A., Kayode, J. F., Ongbali, S. O., Airewa, I., & Edun, B. M. (2023). Impact of Maintenance on Machine Reliability: A Review. *E3S Web of Conferences*, 430. <https://doi.org/10.1051/e3sconf/202343001226>
- Santos, V. (2022). *Applied Artificial Intelligence Draft Edition (v0.1)*.
- Saran, D. J., Brustello Saran, M. C., & Franzotti, C. L. (2024). *O IMPACTO DA INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO INDUSTRIAL: benefícios, desafios e tendências*. e7114. <https://doi.org/10.33635/sitefa.v7i1.304>
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Sharifani, K., & Amini, M. (n.d.). Machine Learning and Deep Learning: A Review of Methods and Applications. In *World Information Technology and Engineering Journal* (Vol. 10). <https://ssrn.com/abstract=4458723>
- Zhang, C., & Lu, Y. (2021). Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration*, 23. <https://doi.org/10.1016/j.jii.2021.100224>

Zhang, T., Lin, W., Vogelmann, A. M., Zhang, M., Xie, S., Qin, Y., & Golaz, J. (2021). Improving Convection Trigger Functions in Deep Convective Parameterization Schemes Using Machine Learning. *Journal of Advances in Modeling Earth Systems*, 13(5). <https://doi.org/10.1029/2020MS002365>

