

M

MESTRADO
Engenharia Informática

Sistema de previsão e acompanhamento de
projetos na indústria
José Fernando Pereira Ribeiro

10/2022

José Fernando Pereira Ribeiro.

Sistema de previsão e acompanhamento de projetos na indústria


M

MESTRADO
Engenharia Informática

Sistema de previsão e
acompanhamento de projetos na
indústria

José Fernando Pereira Ribeiro

10/2022



ESCOLA
SUPERIOR
DE TECNOLOGIA
E GESTÃO
POLITÉCNICO
DO PORTO

P.PORTO

M

MESTRADO
Engenharia Informática

Sistema de previsão e acompanhamento de projetos na indústria

José Fernando Pereira Ribeiro

Orientador: João Ricardo Martins Ramos

Resumo

Competitividade é um termo muito presente nas empresas em diversos setores de atividade. Para manter níveis competitivos mais altos, a qualidade do produto e o atendimento ao cliente são imprescindíveis. Com efeito, ao estabelecer um contrato com um cliente que englobe uma entrega (produto físico ou *software*), é importante cumprir o contrato. Assim, um bom procedimento de previsão é um facilitador para garantir que o cronograma de entrega estabelecido seja executado sem atrasos. Com o desenvolvimento deste trabalho, o objetivo é aplicar técnicas de Inteligência Artificial para garantir as melhores previsões para cada etapa de produção da encomenda a ser fabricada. Posteriormente aplicar a gestão de projetos para aumentar o nível de gestão, planeamento e organização da empresa, de tal forma, que seja possível saber em que dia e hora cada etapa deve estar em produção. Deste modo, ao verificar a última etapa da encomenda é possível saber quando a encomenda estará completa. Através de um bom planeamento é possível aumentar o nível de confiança entre empresa e clientes.

O sistema proposto, que está desenvolvido será aplicado em uma empresa metalúrgica, está subdividido em duas etapas principais: (i) sistema de previsão com modelos de Inteligência Artificial, como Redes Neurais Artificiais, para prever a duração das etapas, e (ii) integração da gestão de projetos que, a partir das previsões anteriores, cria um cronograma que garante a correta execução do projeto. De facto, através da fase (i), pode estimar-se a duração de todas as subtarefas do projeto e, em (ii) as subtarefas de todos os projetos são agendadas e os recursos são alocados. Considerando a quarta revolução da indústria que introduziu conceitos como a digitalização e sensorização (ou seja, utilização intensiva de sensores) existe um volume dados cada vez maior que implica uma maior capacidade de processamento. Sistemas de apoio à decisão que processem este conjunto de dados e providenciem informação precisa são, por este motivo, de extrema importância. A capacidade de automatizar tarefas é também uma vantagem competitiva.

Para o desenvolvimento de sistemas inteligentes são utilizadas técnicas/algoritmos de *Machine Learning* de modo a extrair conhecimento dos dados armazenados. Pretende-se, deste modo, aplicar estes conceitos de extração e utilização de conhecimento, e automatização de processos em organizações de modo a facilitar a sua transformação digital.

Palavras-chave: Modelos de previsão, Gestão de projetos, *Machine learning*, Rede neuronal artificial, Sistema de apoio à decisão.

Abstract

Competitiveness is a term that is very present in companies across several activity sectors. To keep higher competitive levels, product's quality and customer service are a must. Indeed, by establishing a contract with a client that encompass a delivery (physical product or software), it is important to comply with the contract. As such, a good forecasting procedure is a facilitator to ensure that the established delivery schedule is executed without delays. With the development of this work, the goal is to apply Artificial Intelligence techniques to guarantee the best predictions for each production stage of the order to be manufactured. Then apply project management to increase the level of management, planning and organization of the company, so that it is possible to know on what day and time each step should be in production. This way, by checking the last step of the order you can know when the order will be complete. Through good planning it is possible to increase the level of trust between company and customers.

The proposed system, which is under development and is to be applied in a metalworking company, is subdivided in two main stages: (i) forecasting system with Artificial Intelligent models, such as Artificial Neural Networks, to predict production dates, and (ii) project management integration that, using the previous predictions, create a schedule that ensures the correct execution of the project. Indeed, through phase (i), one may estimate the duration of all project's subtasks and, in (ii) subtasks of all projects are schedule and resources are allocated. Considering the fourth industry revolution which introduced concepts as digitalization and sensing (i.e., sensor-intensive) there is an ever-increasing volume of data that requires more processing capacity. Decision support systems that process this data set and provide accurate information are, for this reason, of extreme importance. The ability to automate tasks is also a competitive advantage.

For the development of intelligent systems techniques/algorithms are used Machine Learning in order to extract knowledge from the stored data. It is intended, in this way, apply these concepts of knowledge extraction and use, and process automation in organizations in order to facilitate their digital transformation.

Keywords: Prediction models, Project Management, Machine learning, Artificial Neural Network, Decision Support System.

Índice

Resumo	1
Abstract	3
Índice	4
Lista de tabelas.....	7
Lista de figuras.....	8
Lista de abreviaturas.....	10
1. Introdução.....	12
1.1 Motivação.....	14
1.1.1 Sistemas inteligentes na indústria	14
1.1.2 Previsão e gestão de projetos.....	14
1.2 Apresentação e Oportunidade do Tema.....	15
1.3 Objetivos do trabalho	16
1.4 Metodologia de Investigação	16
1.5 Estrutura do Documento.....	17
2. Sistemas Inteligentes.....	19
2.1 Árvore de Decisão	22
2.2 Redes Neurais	24
2.3 <i>Support Vector Machines</i>	28
2.4 <i>Redes Bayesianas</i>	30
2.5 Aprendizagem por reforço.....	31
2.6 Algoritmos Genéticos	32
3. Sistemas de previsão na indústria.....	36
3.1 Empresa	36
3.2 Etapas.....	36
3.2.1 Corte	36
3.2.2 Dobra.....	36
3.2.3 Furo.....	37
3.2.4 Solda.....	37
3.2.5 Tratamento	38

3.2.6	Acabamento	38
3.2.7	Encomendas finalizadas:	38
3.3	Aplicação de métodos de previsão na indústria	39
3.4	Gestão de projetos industriais	39
3.5	Casos de estudo	40
4.	Estudo de Caso	43
4.1	Apresentação do Estudo de Caso	43
4.2	Tecnologias utilizadas.....	44
4.2.1	<i>Visual Studio Code</i>	44
4.2.2	<i>Pycharm</i>	44
4.2.3	<i>Swagger</i>	44
4.2.4	<i>MongoDB</i>	44
4.2.5	<i>PyMongo</i>	45
4.2.6	<i>Sklearn</i>	45
4.2.7	<i>Pickle</i>	45
4.2.8	<i>Pandas</i>	45
4.2.9	<i>Numpy</i>	45
4.2.10	<i>Python</i>	45
4.2.11	<i>Angular</i>	46
4.3	Arquitetura.....	46
4.4	<i>Back-end</i>	47
4.4.1	Dataset.....	47
4.4.2	Algoritmo de <i>Machine Learning</i>	50
4.4.3	Gestão de projetos	54
4.4.4	<i>Cronjob</i>	56
4.4.5	<i>Swagger</i>	56
4.5	<i>Front-end</i>	61
4.6	<i>Análise crítica aos resultados</i>	68
5.	Conclusões e Trabalho Futuro	69
5.1	Conclusões	69
5.1.1	Contribuições e Discussão de Resultados.....	69
5.1.2	Trabalho realizado (conferências)	70
5.2	Trabalho Futuro.....	70
	Referencias bibliográficas	71

Apêndice 77

Lista de tabelas

Tabela 1 - Variáveis e tipo de dados	48
Tabela 2 - Configurações testadas para treino da rede	52
Tabela 3 - Resultados	53
Tabela 4 - Desvio Padrão.....	53
Tabela 5 - Gestão de projetos	55
Tabela 6 - Endpoints de visualizado de registros.....	57
Tabela 7 - Endpoints do gráfico.....	58
Tabela 8 - Endpoint Post relacionado a empresa	59
Tabela 9 - Endpoint Put relacionado a empresa	59
Tabela 10 - Endpoints relacionados a previsão	60
Tabela 11 - Dados da empresa	61

Lista de figuras

Figura 1 - Fluxo do projeto	21
Figura 2 - Fórmula RMSE, retirado de [40]	21
Figura 3 - Fórmula MAE, retirado de [41]	21
Figura 4 - Fluxo do algoritmo - Árvore de decisão, adaptado de [25].....	23
Figura 5 - Perceptron Model, retirado de [26]	24
Figura 6 - Computador Mark 1, retirado de [27].....	25
Figura 7 - Comparação do neurónio biológico e artificial, adaptado de [28].....	26
Figura 8 - Camadas da rede neuronal artificial, retirado de [29]	27
Figura 9 - Funções de ativação, retirado de [30].....	28
Figura 10 - Exemplo de SVM, retirado de [31].....	29
Figura 11 - Grafo Direcionado Acíclico, retirado de [32]	31
Figura 12 - Estrutura do modelo, retirado de [33]	32
Figura 13 - Representação da estrutura do algoritmo genético, retirado de [34].....	32
Figura 14 - Exemplo de cruzamento, retirado de [35]	33
Figura 15 - Exemplo de mutação, retirado de [35]	34
Figura 16 - Processo do algoritmo genérico, retirado de [36]	34
Figura 17 – Roleta, retirado de [37]	35
Figura 18 - Ciclo do algoritmo genérico, retirado de [38]	35
Figura 19 - Representação da etapa corte	36
Figura 20 - Representação da etapa dobra	37
Figura 21 - Representação da etapa furo	37
Figura 22 - Representação da etapa solda.....	37
Figura 23 - Representação da etapa tratamento	38
Figura 24 - Representação da etapa acabamento.....	38
Figura 25 - Encomendas finalizadas.....	38
Figura 26 - Arquitetura.....	47
Figura 27 – Processo de treino do modelo	51
Figura 28 - Fluxo da GP	54
Figura 29 - Esquema do Cronjob.....	56
Figura 30 - Visualização dos registos	57
Figura 31 - Métodos do gráfico.....	58
Figura 32 - Métodos de empresa.....	59
Figura 33 - Grupo de métodos para previsão	60
Figura 34 – UI – Empresa	63
Figura 35 - Informações da empresa.....	63

Figura 36 - UI - Lista de etapas para previsões	64
Figura 37 - UI - Formulário de previsão da etapa de acabamento	65
Figura 38 - UI - Previsão da etapa corte	65
Figura 39 - UI - Gestão de projetos	66
Figura 40 - UI - Informação das etapas ativadas	67
Figura 41 - UI - Informação das etapas finalizadas	68
Figura 42 - UI - Adicionar empresa	77
Figura 43 - UI - Alteração da empresa	77
Figura 44 - UI – Formulário de previsão da etapa de corte	78
Figura 45 - UI - Formulário de previsão da etapa de dobra	78
Figura 46 - UI - Formulário de previsão da etapa de solda	79
Figura 47 - UI - Formulário de previsão da etapa de furo	79
Figura 48 - UI - Formulário de previsão da etapa de tratamento	80
Figura 49 - Lista de etapas previstas	80
Figura 50 - UI - Previsão da etapa furo	81
Figura 51 - UI - Previsão da etapa dobra	81
Figura 52 - UI - Previsão da etapa solda	81
Figura 53 - UI - Previsão da etapa tratamento	81
Figura 54 - UI - Previsão da etapa acabamento	81
Figura 55 - UI - Inserir valor real	82

Lista de abreviaturas

A

ANN - *Artificial Neural Networks*

API - Interface de programação de aplicações, *Application Programming Interface*

ARIMA - *Autoregressive Integrated Moving Average*

AR - *Action-research*

AG - Algoritmos genéticos

C

CEO - Chief Executive Officer

CPU - *Central Processing Unit*

CNN - *Convolutional Neural Network*

D

Dataset - *Corresponde a um conjunto de dados*

DT - *Decision trees*

DL - *Deep Learning*

DAG - Grafo Direcionado Acíclico

E

ESTG - Escola Superior de Tecnologia e Gestão

F

FIFO - *First In First Out*

G

GP - Gestão de projetos

I

IA - Inteligência artificial

IDE - Ambiente de desenvolvimento integrado, *Integrated Development Environment*

J

JSON - *JavaScript Object Notation*

M

ML - *Machine learning*

MAE - Erro absoluto médio, Mean absolut error

P

PMBOK - *Project Management Body Knowledge*

PME - Pequenas e Médias Empresas

R

REST - Representational State Transfer

RNA - Rede neuronal artificial

ReLU - Rectified Linear Unit

RMSE - Raiz quadrática média, Root mean squared error

S

SVM - *Support Vector Machines*

T

TI - Tecnologia de informação

U

UI – Interface de utilizador

V

VSC – *Visual Studio Code*

VS – Vetores de suporte

1. Introdução

Atualmente as organizações enfrentam uma grande concorrência que, se não for considerada, poderá impedir o seu desenvolvimento e, eventualmente, provocar o término da sua atividade. Um dos pontos-chave para a manutenção do nível de qualidade é o comprometimento com o cliente. Quando se formaliza uma encomenda, vista como um novo projeto, e se estipula o seu prazo de entrega é de extrema importância assegurar o cumprimento do contrato estabelecido, evitando atrasos ou o seu cancelamento.

Nas PME (Pequenas e Médias Empresas) portuguesas não existe, por exemplo, um nível de maturidade superior em contabilidade de gestão [6]. O caráter opcional deste tipo de contabilidade pode ser considerado como sendo um dos principais fatores para o seu baixo nível de aplicação. A partir deste exemplo, pode inferir-se que outras práticas semelhantes são executadas sem uma gestão correta ou sustentável. Deste modo, existem algumas PMEs que estabelecem o prazo de entrega de uma encomenda com base na experiência dos colaboradores da empresa, não sendo aplicada nenhuma ferramenta fiável para assegurar uma estimativa correta dos prazos indicados. Por outro lado, as encomendas são normalmente processadas em formato FIFO (*First In First Out*), ou seja, o cliente que fizer o pedido primeiro será o primeiro a ser atendido. Esta política de conceção dos produtos pode não ser a ideal, dado que não contempla de forma coerente possíveis roturas de matéria-prima, indisponibilidade temporária de mão de obra ou outros fatores que possam invalidar um desenvolvimento contínuo do trabalho programado. Outros fatores que estes tipos de empresas tendem a considerar é o tipo de cliente que realiza a encomenda, ou seja, um cliente conhecido tem habitualmente prioridade face a um novo e nesta situação todo o escalonamento inicialmente estabelecido pode ser alterado sem recurso a uma ferramenta adequada.

Na atualidade, ainda existem muitas empresas que mantêm este processo de gestão manual. A sua preocupação principal é o custo envolvido na produção, existindo um receio elevado na aquisição de novas ferramentas, não sendo considerado o retorno do investimento a médio ou longo prazo. Mantendo as diversas desvantagens ao longo dos anos como, por exemplo, a desorganização no planeamento devido à confusão de qual encomenda tem de ser entregue, desperdício de tempo na realização dos cálculos para estimar prazos de entrega, existindo uma baixa produtividade e possível desperdício de matéria-prima devido às más previsões realizadas manualmente. A principal desvantagem será a insatisfação dos clientes que ficam prejudicados pelo tempo excessivo de espera para terem as suas necessidades atendidas, ocorrendo principalmente nas épocas

sazonais e nas tendências que ocorrem todos os anos como, por exemplo, épocas festivas. Esta falta de comprometimento com o cliente pode implicar a perda do mesmo e resultar em má publicidade, levando a que possíveis futuros clientes optem por outras empresas.

Uma das formas de tentar mitigar as desvantagens anteriormente mencionadas poderá passar pela aquisição de uma ferramenta de *software* que consiga otimizar o processo de previsão das entregas de cada encomenda. Desta forma será possível tentar garantir, de um modo mais fiável, a entrega da encomenda no tempo previsto, diminuindo também o tempo necessário em previsões manuais e aumentando a taxa de sucesso da entrega, melhoria da organização e planeamento. Assim, poder-se-á assumir um maior compromisso com o cliente, ou seja, possibilitar a determinação do período mínimo necessário para que os resultados sejam os mais eficazes, de modo a tornar a empresa mais competitiva, aumentando a satisfação dos clientes [13], que por sua vez pode manter níveis mais elevados de fidelização do cliente e, conseqüentemente, afetar positivamente o lucro da empresa [9].

A qualidade das previsões realizadas poderá revelar-se insuficiente para o cumprimento dos prazos definidos. Uma boa GP (Gestão de projetos) é também fundamental para garantir que todas as etapas do planeamento decorrem com normalidade, não existindo colisões entre projetos. Existem ferramentas específicas para esta atividade, mas que implicam um acréscimo nos custos de produção devido ao seu custo de aquisição. No entanto, com a sua aplicação é possível melhorar o foco nos objetivos, estratégias adquiridas e efetuar todas as etapas necessárias, garantindo uma maior eficiência no processo a concretizar. Com a finalidade de simplificar a gestão é essencial que as empresas escolham bem a metodologia que mais se adequa no contexto de cada negócio, para facilitar o controlo e escalonamento das encomendas. As empresas precisam, geralmente, de coordenar vários pedidos em simultâneo e, para facilitar na escolha da metodologia, é importante que o responsável tenha um bom conhecimento sobre a área de estudo.

A implementação de GP como alavanca para melhorar a competitividade das PMEs portuguesas foi estudada em [16], que demonstrou o seu impacto positivo. No entanto, conforme definido em [18], a gestão de riscos é uma parte essencial da gestão de projetos para PMEs que também deve ser considerada para permitir que as empresas sejam mais livres de riscos e adaptáveis a uma mudança de produção (por exemplo, falta de *stock* bruto).

Na GP existem várias referências na literatura, sendo o PMBOK (*Project Management*

Body Knowledge) [5] uma das mais utilizadas, pois inclui métodos padronizados de boas práticas para a correta elaboração da estrutura do planeamento.

1.1 Motivação

1.1.1 Sistemas inteligentes na indústria

Na sociedade e desenvolvimento tecnológico atuais verifica-se um surgimento contínuo de novas tecnologias com o objetivo de auxiliar e melhorar o quotidiano das pessoas. Este desenvolvimento tem como potenciador a alta capacidade de processamento e a possibilidade de integrar novos sensores/funcionalidades em dispositivos do dia-a-dia, como por exemplo no telemóvel, computador, relógios inteligentes, tablets, entre outros.

Os sistemas inteligentes estão a cada vez mais a ser implementados em diferentes contextos, tal como na área industrial, onde estão a ser utilizados com o intuito de melhorar a gestão da empresa e aumentar a produtividade. Uma empresa que consiga obter e implementar com sucesso tecnologias que permitam um desenvolvimento mais inteligente, possui uma maior vantagem competitiva face aos seus concorrentes diretos. Esta capacitação tecnológica, movida também pela atual revolução industrial (indústria 4.0) implica a utilização de um amplo conjunto de sistemas de tecnologias avançadas, interligadas entre si que permitem trazer os diversos benefícios como capacidade de processamento de grandes volumes de dados e, através de sistemas de inteligência artificial, detetar padrões.

Neste caso de estudo será desenvolvido um sistema inteligente capaz de fazer a previsão de quanto tempo demora uma determinada etapa da produção para se concluir uma encomenda.

1.1.2 Previsão e gestão de projetos

Atualmente no setor industrial as pequenas e médias empresas precisam sair da zona de conforto e ter como objetivo o investimento na inovação, de modo a conseguir dar uma melhor experiência ao seu leque de clientes.

A implementação de um sistema produtivo com capacidade de rápida adaptação ao mercado é um fator determinante para um desenvolvimento sustentável, permitindo um futuro de sucesso e promissor. A alta rotatividade de produtos fabricados, com taxas de produção mais pequenas e sazonais só é passível de ser eficiente se existir uma boa gestão

de projetos. Permitindo facilitar a execução de encomendas, garantindo que não existem colisões e que os prazos estipulados são cumpridos.

Para o gestor de projetos é importante ter conhecimento mais ou menos profundo sobre todos os processos produtivos, estando receptivo também a opiniões para uma melhoria contínua.

A integração de sistemas de Inteligência Artificial pode ser considerada uma mais-valia, especialmente para empresas de PME, uma vez que permite ao gestor a análise de um conjunto maior de dados. Desta forma, a sua visão sobre todos os processos é mais abrangente e contempla dados que, caso não fossem analisados de forma automática, seriam desconhecidos e desconsiderados.

Com base num conhecimento mais detalhado e próximo da realidade pretende-se, com este projeto, o desenvolvimento de um sistema que facilite a gestão de projetos com base em modelos de *Machine Learning*, onde o gestor poderá obter a previsão de conclusão de um projeto (encomenda) e, assim, entregar uma boa experiência às partes envolvidos no processo.

1.2 Apresentação e Oportunidade do Tema

Ao longo dos anos tem-se assistido a alterações no mundo empresarial, onde empresas encerram atividades, outras conseguem mantê-la e novas aparecem num mercado competitivo com novas ideias. Assim, existem mais indivíduos que são criativos, inovadores, estabelecem novas estratégias de negócio, aproveitando as oportunidades promissoras. Para um CEO (*Chief Executive Officer*) de sucesso é necessário ter capacidade de planejar e liderar o melhor possível, de modo a obter resultados eficazes e positivos. É essencial usufruir de um bom plano de negócio, permitindo que o gestor consiga ter informação necessária para realizar um bom planeamento, conseguindo determinar as estratégias que são mais benéficas para a empresa, intensificando o crescimento de modo a destacar-se de outras empresas concorrentes. Atualmente muitas empresas consideradas de sucesso funcionam durante muito tempo sem um plano de negócios bem definido. Esta falta de planeamento pode tornar-se num risco elevado, dado que desconsidera possíveis alterações no mercado a médio/longo prazo, podendo inviabilizar a manutenção da atividade em determinadas condições de laboração.

Para se proporcionar a manutenção ou aumento da taxa de sucesso de uma empresa num ambiente que está em constante e rápida evolução, são necessários novos investimentos em diversas áreas, nomeadamente na formação dos colaboradores, melhoria de

infraestruturas, maquinaria e tecnologia. O correto investimento torna as empresas mais produtivas, eficientes e seguras. Tem também como benefício o aumento das oportunidades de negócio, aumento da satisfação dos clientes, redução de custos, ganho de competitividade no mercado de trabalho e crescimento económico [14].

Considerando todos os fatores mencionados, pretende-se a realização de um estudo aplicado as empresas de pequena/média dimensão do setor de metalomecânica, onde atualmente se verifica a realização manual das previsões para os prazos de entrega de novas encomendas e a inexistência de uma metodologia que permita uma gestão de projetos eficiente.

1.3 Objetivos do trabalho

O objetivo do presente trabalho consiste no estudo do modo como se processam as encomendas dos clientes, a realização das previsões para os prazos de entrega e da metodologia aplicada para gestão de todo o processo produtivo. Desta forma, e considerando a aplicabilidade da solução proposta, pretende-se automatizar todo o sistema através da aplicação de um modelo de *Machine Learning*, mais concretamente uma rede neuronal artificial para a realização de previsões de boa qualidade em função do produto e quantidade encomendada. O funcionamento não linear desta técnica de *Machine Learning* é um ponto forte na melhor identificação de padrões/comportamentos dos dados [20]. Com este algoritmo, através da realização de treinos diferentes, pretende-se também dotar o sistema com a capacidade de determinar as etapas necessárias para a execução de um objeto e duração das mesmas, e posteriormente, a criação automática de um plano para a execução da encomenda tendo em consideração todas as fases necessárias à sua realização.

Nesse sentido, considera-se que cada encomenda corresponde a um projeto que, através das metodologias mais adequadas na área de gestão de projetos, terá de ser implementado, permitindo ajustes e verificação de possíveis colisões com outros projetos ou necessidade de novo escalonamento para diminuir possíveis atrasos na finalização de uma encomenda. No final pretende-se que o sistema auxilie na tomada de decisão do gestor de modo a garantir a eficiência e eficácia do processo produtivo.

1.4 Metodologia de Investigação

A metodologia que será aplicada no trabalho de investigação é a AR (*action-research*), constituída por um processo de investigação, planeamento e execução de métodos para a solução dos problemas identificados, permitindo alterações céleres devido à análise

sistemática dos resultados obtidos em cada etapa. Esta metodologia consiste num processo cíclico que é iniciado com a identificação do problema e a sua investigação, recolha de informação para planeamento do método de resolução mais adequada e realista. Antes de começar o desenvolvimento do projeto é necessário apresentar a proposta para ser analisada, de modo a obter um feedback da proposta. Caso a proposta seja aceite é iniciada a fase da implementação do projeto, caso contrário é essencial voltar à etapa de investigação até que o retorno do feedback seja positivo. No final é fundamental a avaliação dos resultados obtidos e verificação dos impactos desta solução de modo a avaliar se a mesma é benéfica para o problema apresentado [21].

1.5 Estrutura do Documento

O documento atual encontra-se dividido em 5 capítulos, estruturados de modo a apresentar as temáticas necessárias à apresentação e definição do tema em estudo e, por fim, o trabalho desenvolvido com o objetivo de colmatar alguns dos problemas detetados.

No capítulo 1, Introdução, procede-se à apresentação global do projeto, onde são determinados os principais objetivos a serem alcançados para o mesmo. É ainda apresentada a fundamentação teórica, onde se realiza uma breve descrição dos processos, pesquisa, tecnologias, conceitos e um pouco de história que foram fundamentais para aplicar na solução deste problema.

O capítulo 2, Sistemas Inteligentes, descreve alguns algoritmos que podem ser utilizados para fazer a previsão, utilizando as suas fórmulas matemáticas, para o caso de estudo. Descreve o seu funcionamento, vantagens e desvantagens e os aspetos particulares de cada modelo de aprendizagem máquina (*Machine Learning*).

O capítulo 3, Sistemas de previsão na indústria, apresenta uma revisão da literatura sob os dois principais tópicos abordados, algoritmos de *Machine Learning* para previsões e Gestão de Projetos. Existe ainda dois subcapítulos que detalham brevemente os principais conceitos de ML e GP, respetivamente, e apresentam alguns exemplos de aplicações.

No capítulo 4, Caso de estudo, são apresentadas as tecnologias utilizadas no desenvolvimento do projeto, relatando o desenvolvimento do projeto e descrevendo o algoritmo escolhido para efetuar a previsão para o caso de estudo e como foi desenvolvido a gestão de projetos.

Por fim, no capítulo 5, Conclusões e Trabalho Futuro, são apresentados os resultados obtidos com o desenvolvimento do projeto proposto, os dados são apresentados de forma

estruturada em tabelas, permitindo abordar de forma crítica os resultados obtidos e os principais desafios encontrados ao longo do desenvolvimento. Também é elaborada uma avaliação do trabalho realizado, expondo uma reflexão crítica do projeto como um todo, de forma a definir aspetos e ideias a melhorar no trabalho futuro.

2. Sistemas Inteligentes

Um sistema inteligente [51] tem como objetivo auxiliar no cotidiano do ser humano e o processo de tomada de decisão dado um conjunto de informações e uma variedade de ações possíveis, ou seja, é um sistema de apoio à decisão que ajuda a resolver problemas não estruturados. Estes sistemas utilizam técnicas de IA para a resolução de problemas, podendo ser, algoritmos genéticos, redes *bayesianas*, aprendizagem por reforço, redes neuronais, entre outros. Estas aplicações podem ser utilizadas para resolver problemas como a decodificação de chaves secretas, planejamento da trajetória de um robô/carro, controle de transmissão de gasoduto, caixeiro-viajante, transmissão de energia elétrica, gestão de recursos, agricultura, jogos, entre outros.

A evolução destes sistemas de IA está a afetar a indústria, de tal forma, que as empresas estão a investir gradualmente na tecnologia, tornando a sua produção mais eficaz e eficiente, aumentando consequentemente a sua competitividade no mercado.

Na área da Inteligência Artificial existem vários algoritmos que podem ser aplicados, cada um com as suas vantagens/desvantagens ou critérios específicos para a sua aplicação. Deste modo, os algoritmos podem ser divididos de acordo com o tipo de aprendizagem realizada: supervisionada, não supervisionada ou por reforço.

A aprendizagem supervisionada é um método de análise de dados que usa técnicas que aprendem iterativamente a partir dos dados de modo a identificar padrões e criar um conjunto genérico de regras. Neste grupo de algoritmos podem ser incluídos exemplos como Regressão linear, Regressão logística, Redes Neuronais Artificiais, *Support Vector Machine*. De acordo com o resultado pretendido poder-se-á ainda subdividir esta categoria de algoritmos em problemas de regressão ou de classificação:

- Regressão: Nos problemas de regressão o algoritmo é treinado para prever valores com base num conjunto de dados de *input*, tendo como *output* um valor numérico (exemplo de problemas: preço de imóvel, número de vendas).
- Classificação: Nos problemas de classificação o algoritmo é usado para classificar os dados de *input* em variáveis discretas, tendo como resultado a classificação de um determinado evento acontecer (exemplo de problemas: classificar cliente de uma loja na compra de produtos, classificação de *spam*).

A aprendizagem não supervisionada contém métodos cujo objetivo é identificar novos padrões e detetar anomalias. Estes métodos tentam determinar padrões de acordo com um conjunto de regras, como por exemplo, proximidade de exemplos vizinhos e, com base nessa determinação agrupá-los em classes ou eventos específicos. Dentro desta classe poder-se-ão encontrar algoritmos como *Clustering* e *Dimensionality reduction*.

A aprendizagem por reforço difere das abordagens anteriores, uma vez que não requer um conjunto prévio de dados para treino. A aprendizagem é realizada com base na realização de ações sobre o ambiente e consequente *feedback* recebido, ou seja, há uma interação constante com o ambiente, sendo possível determinar o seu estado atual e o estado alterado após a ação, existindo uma política de recompensas. A recompensa representa o resultado da ação previamente executada e, com base nesta, é realizada a aprendizagem, ou seja, é possível afirmar que a aprendizagem é realizada por tentativa e erro.

De entre as categorias de algoritmos referidos anteriormente e considerando as suas características gerais selecionou-se a categoria de algoritmos de aprendizagem supervisionada, devido às suas capacidades de aprender com os dados fornecidos, definindo pesos aos vários atributos e com possibilidade de realizar previsões mais próximas da realidade.

De um modo geral, o desenvolvimento e aplicação de algoritmos supervisionados segue o fluxo apresentado na figura 1. Este fluxo é constituído por quatro etapas principais, iniciando-se pela identificação das variáveis que melhor descrevem o problema. De seguida, é necessário adquirir e, em função do tipo ou valor das variáveis, poderá ser necessário realizar uma transformação aos dados. Daqui resulta, por exemplo, a conversão de dados categóricos em dados numéricos (de modo a serem utilizados pelas técnicas de ML), verificação de valores *outliers* ou em falta, e normalização de variáveis. No final desta etapa, os dados estão prontos a serem utilizados pelo modelo selecionado. Após treino, teste e validação do modelo pode ser necessário rever o processo completo caso os resultados não sejam satisfatórios, ou poder-se-á utilizar o modelo para realizar previsões sobre dados novos.

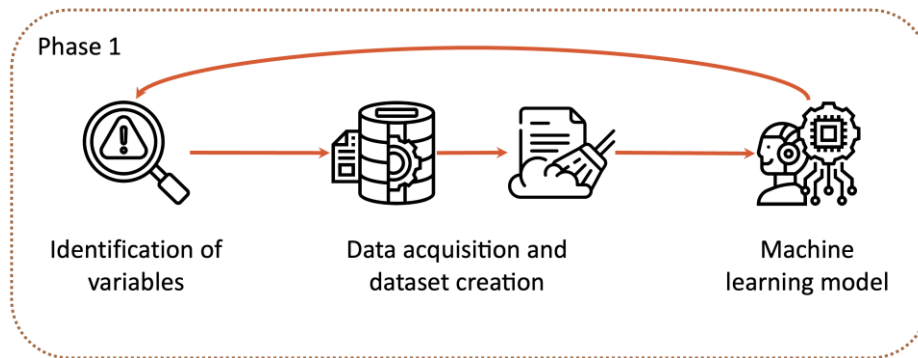


Figura 1 - Fluxo do projeto

A avaliação da qualidade do modelo treinado pode ser realizada de múltiplas formas, sendo as principais a métrica *root mean square* e *mean average error* para dados contínuos e a *accuracy* para dados categóricos.

A métrica (RMSE) *root mean square error* ou erro quadrático médio (figura 2) é responsável por indicar a proximidade entre os valores estimados com os valores atuais. Quanto menor for o valor calculado, melhor será o resultado, indicando uma boa *performance* do modelo.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}$$

Figura 2 - Fórmula RMSE, retirado de [40]

A métrica (MAE) *mean absolute error* ou erro absoluto médio (figura 3) é responsável por determinar a média da diferença entre o valor real com o valor previsto. Considera-se que o modelo possui um bom resultado de treino/teste quando esta métrica apresenta valores baixos.

$$MAE = \frac{1}{m} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Figura 3 - Fórmula MAE, retirado de [41]

2.1 Árvore de Decisão

A árvore de decisão ou *decision tree* (DT) [52] é um algoritmo de aprendizagem máquina supervisionado que é aplicada para problemas de classificação e regressão, sendo considerada como uma das mais intuitivas para interpretar/visualizar. A representação visual em formato de árvore facilita a compreensão dos dados quando em comparação com, por exemplo, a caixa negra que é uma rede neuronal (ver secção Redes Neurais) e das funções matemáticas dos modelos lineares. Uma DT é um mapa de diversos resultados de um conjunto de escolhas relacionadas, permitindo a uma entidade comparar e conferir possíveis comportamentos, atitudes ou ações tendo como base os seus custos, probabilidades, vantagens e desvantagens. A árvore de decisão pode ser utilizada em múltiplos cenários, nomeadamente para previsão (matemática) da melhor opção/valor ou para conduzir diálogos informais.

Cada nível da árvore de decisão denota uma seleção de acordo com a variável mais representativa, realizando uma fragmentação dos dados nesse nível e com impacto nos níveis subsequentes.

Uma DT é composta por:

- Um único nó inicial, designado de nó raiz;
- Nós internos, que testam os atributos;
- Ramos, que representam conjunções de variáveis/valor do atributo;
- Folhas que são resultados da previsão para aquele caminho.

Como se pode verificar pela figura 5 que a DT começa, normalmente, com um único nó, que se divide em possíveis resultados, resultando nos nós internos que estão conectados aos ramos que chegam e partem de cada nó interno. As folhas, por sua vez, possuem apenas ramificações que chegam a elas e nenhum ramo partindo delas, o que implica o fim da DT e a obtenção de uma resposta.

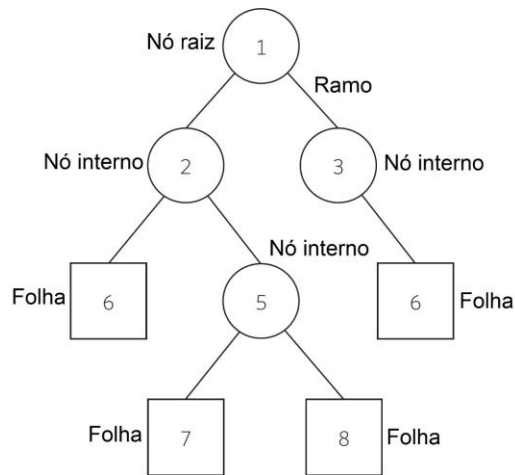


Figura 4 - Fluxo do algoritmo - Árvore de decisão, adaptado de [25]

O treino da árvore de decisão começa com a partição do conjunto inicial de dados em subconjuntos, designados de nós internos. A divisão é feita com base no atributo que permite um maior ganho de informação, podendo ser:

- redução de incerteza;
- aumento da medida de pureza.

O processo repete-se recursivamente até alcançar um critério de paragem, como por exemplo:

- Medida de pureza;
- Profundidade da árvore;
- Número de folhas.

A utilização deste algoritmo tem como vantagens a fácil interpretação, percebendo a razão da decisão, uma vez que os atributos mais relevantes aparecem mais na parte superior da árvore e é adaptável a problemas de regressão, ou seja, caso em que as folhas têm a média dos valores que foram atribuídos, mas continuam a não fazer a previsão de valores contínuos. Contudo este algoritmo tem as suas desvantagens, podendo tornar os padrões mais complexos, ou seja, cada auditor tem um modelo mental diferente, existem muitos cenários diferentes, número de variáveis e quantidade de dados pode ser elevado, e devido a esta consequência deve-se verificar a condição de paragem. Também se deve ter em conta a sensibilidade a pequenas perturbações no conjunto de treino. Por outro lado, as árvores muito complexas podem ser difíceis de interpretar (devido ao elevado número de nós), tempo de treino pode ser elevado e há a possibilidade de sofrer de *overfitting*.

O *overfitting* ocorre quando um modelo fica demasiado adaptado aos dados de treino, tendo uma fraca generalização. O modelo possui um desempenho excelente nos dados de treino, mas nos dados de teste o resultado é fraco. Este tipo de árvore que não teve em consideração evitar o *overfitting* será uma árvore com muitos níveis, mas com regras muito frágeis. Este modelo aprende tão bem as relações existente no treino, decorando o que deve fazer, que quando realiza a regressão com os dados de teste não consegue aplicar com sucesso as mesmas regras, afetando o desempenho.

2.2 Redes Neurais

Uma rede neuronal [53] é um algoritmo de aprendizagem [23] que foi modelado nos anos 50, tendo a intenção de criar um modelo computacional inspirado na forma como as redes neuronais biológicas processam informação, ou seja, de forma a simular o funcionamento do cérebro utilizando circuitos elétricos. A primeira rede neuronal artificial (RNA) desenvolvida foi designada de *perceptron* (P). É um modelo matemático que recebe no *input* várias *inputs* de dados e produz uma única saída binária, como se pode verificar na figura 6.




Figura 5 - Perceptron Model, retirado de [26]

Foi inicialmente desenvolvida para ser uma máquina, designada de Mark 1, desenhada para tarefas de reconhecimento de imagem, com 400 fotocélulas ligadas aos neurónios. Os pesos eram codificados com potenciômetros e a atualização dos pesos era feita através de motores elétricos (figura 7). Esperava-se que evoluísse para a complexidade do cérebro humano com o objeto de executar todas as tarefas que o ser humano consegue realizar. Contudo a evolução consistiu no desenvolvimento de modelos baseados em *software* que

foram potenciados pelo aumento do poder computacional, que foi essencial para resolver problemas complexos. Conseguindo, por exemplo, inicialmente ser aplicado nos campos:

- Reconhecimento de imagens
- Reconhecimento da fala
- Processamento de texto



Figura 6 - Computador *Mark 1*, retirado de [27]

Este algoritmo é uma rede de unidades de processamento interligadas cujo objetivo é dar um *output* a partir dos dados de entrada e pode ser utilizado para a aprendizagem supervisionada e para aprendizagem não supervisionada. Este algoritmo é bastante popular em problemas de classificação e regressão, tendo sido cada vez mais usado no campo de ML nos últimos anos.

Estas redes são sistemas de computação inspirados de forma a funcionar de maneira semelhante as redes neurais biológicas que constituem o cérebro humano. O cérebro tem como unidade computacional básica do sistema nervoso o neurónio, possuindo aproximadamente 86 mil milhões de neurónios, interligados por aproximadamente 10^{14} sinapses.

Na transmissão de sinais cerebrais, um neurónio recebe vários sinais de entrada de outros neurónios através dos dendritos, que são um conjunto de terminais de entrada. Após receção destes sinais, o neurónio processa-os e, em seguida, transmite-os para outros neurónios através dos terminais axónicos que são longos terminais de saída. RNAs são a tradução desse fato para um modelo computacional e são constituídos por muitos neurónios artificiais interligados, por ligações que transferem o *output* de um neurónio para o neurónio seguinte, e cada um desses neurónios tem um peso (W_{ij}) associado que indica a

importância da ligação, e emite uma resposta. A figura 8, compara um neurónio cerebral com um neurónio artificial.




Figura 7 - Comparação do neurónio biológico e artificial, adaptado de [28]

Na figura 9, observa-se que uma rede neural artificial possui, na sua forma mais básica, três camadas de neurónios (unidades):

- A camada de entrada: o ponto de entrada dos dados (*Input Layer*);
- A camada oculta: onde a informação é processada (*Hidden Layer*);
- A camada de saída: recebendo a resposta do processamento dos dados (*Output Layer*).

A camada *input layer* é um modelo computacional onde existe um neurónio para cada variável do input, ou seja, é composto por um conjunto de neurónios que têm como função receber dados do “exterior” e tem como objetivo passar a informação para a próxima camada.

A camada *hidden layer* (camada intermédia ou camada oculta) é a camada onde ocorre a aprendizagem e a cada camada interna tem 1/2 ou 1/3 dos neurónios da camada anterior.

A camada *output layer* é constituída pelos neurónios de *output* que origina o resultado final. Numa RNA de classificação existe um neurónio por cada variável dependente, enquanto numa RNA de regressão existe um único neurónio como resultado.




Figura 8 - Camadas da rede neuronal artificial, retirado de [29]

Se a RNA fosse apenas camadas de entrada e saída, isto é, não contivesse nenhuma camada intermédia, seria apenas uma aproximação linear onde o *output* é 0 ou 1 (para o problema de classificação). As camadas internas são as responsáveis pela introdução da não linearidade que uma RNA possui. Desta forma, sendo o *output* contínuo, é possível modelar problemas mais complexos. Para garantir que o *output* não seja apenas uma influência da soma dos pesos (W_{ij}) é adicionado a cada neurónio artificial simples uma função de ativação. Para problemas de classificação pretende-se que a função de ativação permita um *output* com valores 0 ou 1, enquanto, em problemas de regressão, a função de ativação utilizada pode permitir qualquer valor como *output*. Na Figura 9 - Funções de ativação 10, pode verificar-se que existem várias funções de ativação diferentes.




Figura 9 - Funções de ativação, retirado de [30]

Os neurónios artificiais, quando combinados, compõem as RNAs e embora consigam resultados admiráveis em muitos campos, existem algumas limitações nesses modelos como, por exemplo, *overfitting* e *overtraining*.

O *overfitting* refere-se a um modelo que modela muito bem-adaptado aos dados de treino (erro obtido próximo de zero), mas pode mostrar-se ineficaz para prever novos resultados. Podendo ter como consequência o *overtraining*, que ocorre se a rede neuronal é muito poderosa para o problema atual, mas não é capaz de reconhecer a tendência subjacente nos dados. Deste modo considera-se que a rede aprende com os dados através da memorização, ou seja, reconhece não só possíveis tendências, mas também o ruído existente nos dados de treino. Deste processo resulta uma má generalização e um ajuste muito bom para os dados de treino. Então uma resposta lógica de prevenção seria interromper o processo de treino mais cedo, também designado por interrupção precoce ou reduzir a complexidade no modelo, eliminando alguns *inputs* menos relevantes.

2.3 Support Vector Machines

SVM (*Support Vector Machines*) [54] é uma técnica de aprendizagem máquina supervisionada que normalmente analisa dados e é utilizada para problemas de classificação (linear ou não linear) para reconhecimento de padrões. No entanto, pode também ser utilizada para problemas de regressão para previsão de novos valores.

Nesta técnica cada exemplo de treino é visto como um ponto no espaço n -dimensional, onde n é o número de atributos que a base de dados possui, onde o valor de cada atributo representa o valor de uma determinada coordenada.

Ao processar a informação o algoritmo constrói uma representação dos pontos no espaço com o objetivo de um dividir em (pelo menos) duas classes. Com base nas coordenadas dos pontos, pretende-se determinar o melhor plano (ou hiperplano) que melhor separa os dados em classes. Para tal são determinados os melhores vetores tendo, também, em consideração a classificação (classe a que pertence um ponto) existente na base de dados, de modo a minimizar o erro de classificação. A figura 11 apresenta um exemplo de um hiperplano no espaço bidimensional. O espaço vazio que se encontra entre o hiperplano e o primeiro ponto de um dos conjuntos designa-se por margem e deve ter o maior valor possível.

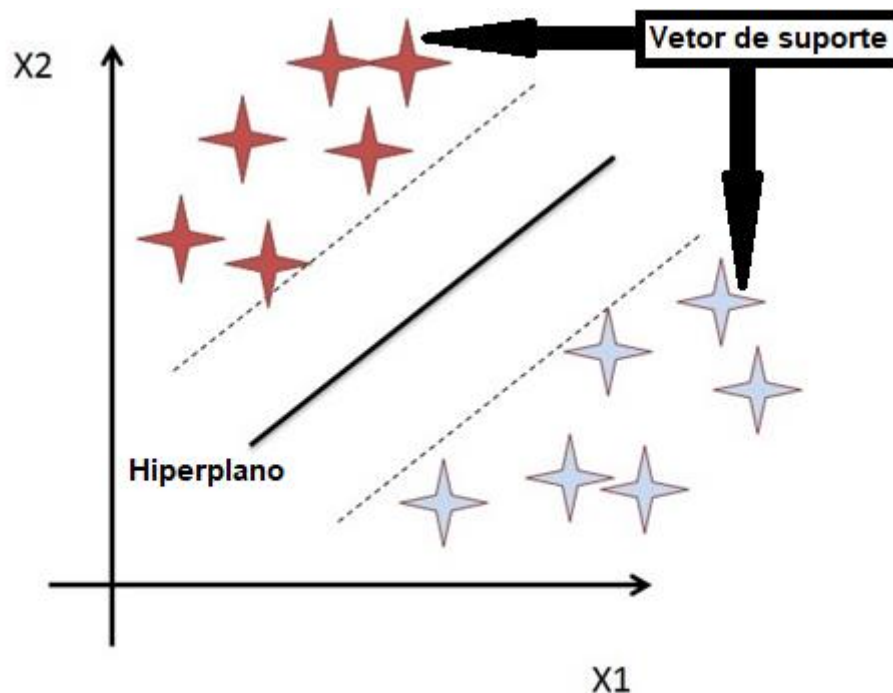


Figura 10 - Exemplo de SVM, retirado de [31]

A utilização de uma SVM possui várias vantagens, nomeadamente:

- Funciona bem com margem de separação bem clara;
- É eficiente nos casos de estudo em que o número da dimensão é maior que o número de amostras;
- Utiliza, de forma eficiente, o uso de memória durante o treino, ou seja, possui boa performance.
- Boa capacidade de generalização, alcançado bons resultados;
- É robusto diante objetos de grandes dimensões, como por exemplo, as imagens;

- Tem a teoria bem definida, possuindo uma base teórica bem estabelecida na área da Matemática.

No entanto, a SVM apresenta as seguintes desvantagens:

- Não possui um bom desempenho perante uma base de dados de grande dimensão, devido ao tempo de treino ser extremamente elevado;
- Não funciona bem quando os dados possuem ruído;
- Não é apropriado para problemas não lineares.

2.4 Redes Bayesianas

As RB (Redes Bayesianas) [55] são um método de raciocínio que representa relações de probabilidade condicional e desenvolveu-se com o objetivo de facilitar as tarefas de previsão e abdução nos sistemas de IA (Inteligência Artificial).

Esta técnica de raciocínio probabilístico engloba a teoria dos grafos para a determinação das ligações das relações (qualitativa) e também a teoria das probabilidades que permite atribuir o grau de confiabilidade (quantitativa). A diferença entre o raciocínio probabilístico e o raciocínio determinístico é que no raciocínio probabilístico é possível escolher as decisões racionais sem ter a informação necessária para confirmar que uma determinada ação pode ou não ter um bom resultado. Este mecanismo tem sido utilizado em várias abordagens, tal como:

- Diagnósticos médicos;
- Mapas de aprendizagem;
- Visão por computador (*computer vision*);
- Pesquisa heurística.

Uma RB consiste em conjuntos de variáveis e conjuntos de arcos que ligam as variáveis. Cada variável possui um conjunto limitado de estados e quando as variáveis e os arcos constituem um grafo sem ciclos designa-se por grafo direcionado acíclico (DAG – *Directed Acyclic Graph*). Neste tipo de grafo os arcos representam as relações causais entre as variáveis, ou seja, indicam as probabilidades condicionais. Para cada vértice X com n antecessores Y é possível elaborar um gráfico DAG onde a probabilidade de X é dada por $P(X|(Y_1, Y_2, \dots, Y_n))$, como se pode verificar na figura 12.




Figura 11 - Grafo Direcionado Acíclico, retirado de [32]

2.5 Aprendizagem por reforço

A aprendizagem por reforço [56] é uma técnica de *Machine Learning* que consiste em aprender com as ações que são realizadas. Após a execução das referidas ações, é determinada a recompensa (positiva ou negativa) dessa ação, obtendo-se a experiência necessária para obter cada vez melhores resultados. É um método onde o envolvimento humano é limitado, permitindo a aprendizagem num ambiente dinâmico através de ações que consistem em tentativa e erro.

Esta abordagem é composta por um agente, ambiente, estado, política e recompensa, como se pode verificar na figura 13. Neste tipo de modelos de *Machine Learning* é necessário identificar/determinar:

- O agente: tem como objetivo atingir uma meta ou condição num ambiente potencialmente complexo e que tem como função tomar decisões/ações de modo a interagir com o ambiente.
- O ambiente e o problema: determinar o que se pretende solucionar pelo *software*, onde o agente realiza as suas ações.
- O Estado: indica como um sistema que se encontra em uma determinada instância. Este estado é alterado quando o agente executa uma ação no ambiente alterando-o, ou seja, é definido de acordo com a recompensa para o agente.
- A política: consiste na estratégia implementada, ou seja, as regras que o agente possui para decidir as ações que pode executar com base no estado.
- A recompensa: é a resposta da ação tomada pelo agente que pode ser benéfica ou prejudicial.

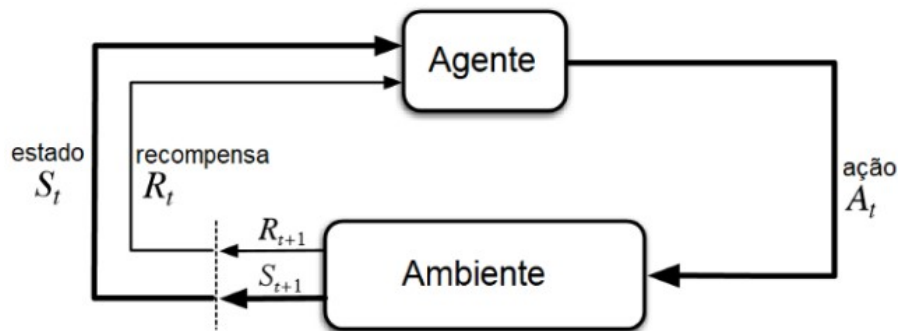


Figura 12 - Estrutura do modelo, retirado de [33]

2.6 Algoritmos Genéticos

Os AG (algoritmos genéticos) [57] são técnicas computacionais inspiradas nos mecanismos de evolução natural que trabalham com probabilidade e possui como objetivo encontrar as várias soluções satisfatórias para problemas complexos. Por não se tratar de um algoritmo exato, não é possível garantir a obtenção da solução ótima, no entanto, a utilização deste modelo permite atingir soluções de boa qualidade. No AG são definidos genes, cromossomas (conjunto de genes) e a população (conjunto de cromossomas), como se pode verificar na figura 14.




Figura 13 - Representação da estrutura do algoritmo genético, retirado de [34]

Estes métodos de pesquisa probabilística são inspirados nos princípios de seleção natural e da genética, que inicialmente começa por possuir uma população (determinado número de indivíduos) num determinado ambiente cujo objetivo é a sua adaptação, da melhor forma possível, ao ambiente. De modo a alcançar o objetivo de se adaptar os indivíduos da população reproduzem-se com a finalidade de gerar outros indivíduos, criando um novo conjunto de indivíduos que poderão constituir a nova geração da população. Em cada nova geração são escolhidos os indivíduos mais aptos para servirem de progenitores para as

gerações seguintes, ou seja, mais adaptados ao ambiente. Desta forma, cria-se um ciclo de evolução ao longo de sucessivas gerações, que permite obter cada vez mais indivíduos bem-adaptados.

Um conjunto de um número determinado de genes é considerado um cromossoma, que representa uma solução possível para o problema. De modo a obter cada evolução positiva e melhor que a anterior, o cromossoma pode ser manipulado de forma a sofrer alterações que o transformam num novo cromossoma. A fim de criar uma população favorável para a nova geração são aplicadas técnicas, tais como:

- Cruzamento; e
- Mutação.

O cruzamento (ou crossover) é uma técnica de transformação que seleciona dois cromossomas e efetua a combinação genética entre os progenitores, gerando um novo cromossoma. Em outras palavras, seleciona um determinado número de genes de cada cromossoma e junta-os, formando uma nova geração de descendentes (figura 15).




Figura 14 - Exemplo de cruzamento, retirado de [35]

A mutação tem como objetivo atuar sobre a solução resultante e alterar ligeiramente os genes originando um novo cromossoma, de modo a aumentar a diversidade na população, como se pode verificar na figura 16.




Figura 15 - Exemplo de mutação, retirado de [35]

De modo a qualificar as novas gerações de cromossomas, estes são submetidos para avaliação. Recorrendo a uma função fitness (índice de aptidão) que associe a cada solução uma medida de qualidade, pretende-se selecionar os cromossomas mais aptos para gerar a próxima geração. Para selecionar os melhores cromossomas pode ser utilizado o elitismo que é uma técnica para selecionar os melhores n cromossomas para a população seguinte. Contudo, se a qualidade do melhor indivíduo de uma nova geração for inferior à geração anterior, é feita a recuperação e adição desses indivíduos na nova população, como se pode verificar na figura 17.




Figura 16 - Processo do algoritmo genérico, retirado de [36]

Porém existem outros métodos para selecionar os indivíduos mais aptos, de modo a serem escolhidos para a reprodução, que são:

- Seleção aleatória;
- Seleção por torneio;
- Roleta.

A seleção aleatória é a técnica de seleção mais simples e ineficiente de selecionar os pais, pois são escolhidos aleatoriamente. A seleção por torneio consiste em selecionar dois indivíduos aleatoriamente, porém quem tiver o maior *fitness* é considerado o vencedor. A técnica roleta expressa-se em representar cada indivíduo por uma fatia proporcional à sua aptidão e, como consequência, é-lhe atribuído uma percentagem (probabilidade) de ser escolhido. Posteriormente, é gerado um número aleatório para efetuar a escolha (exemplo: figura 18).

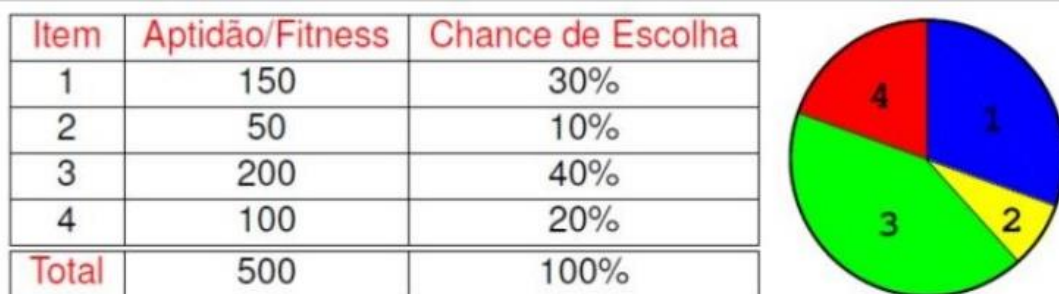


Figura 17 – Roleta, retirado de [37]

Este ciclo termina (Figura 18 - Ciclo do algoritmo genérico) quando um determinado critério de paragem for alcançado. Como critério de paragem pode ser selecionado o número máximo de iterações, qualidade pretendida, tempo total de execução do algoritmo, número total de indivíduos, número de mutações, número de cruzamentos, entre outros.

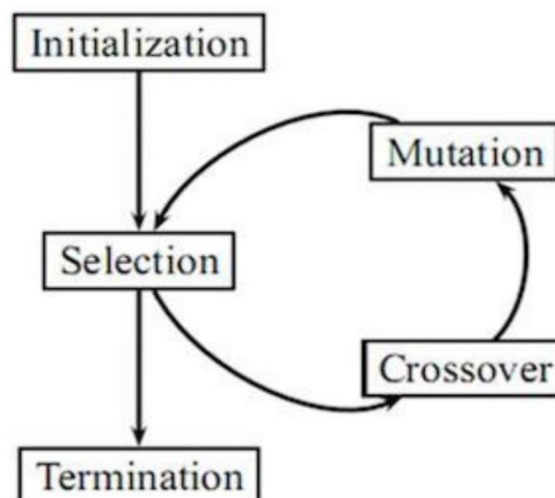


Figura 18 - Ciclo do algoritmo genérico, retirado de [38]

3. Sistemas de previsão na indústria

3.1 Empresa

A PME de caso de estudo é uma empresa do setor metalomecânica ou metalúrgica que possui todos os segmentos responsáveis da transformação de metais. Normalmente a produção de objetos é realizada após o pedido da encomenda pelo cliente. Os produtos desejados podem ser desde a produção de bens como objetos para decoração de casas, serviços intermediários, máquinas, equipamentos e veículos.

3.2 Etapas

A empresa de caso de estudo, fabrica bens para decoração de imóveis, produzindo somente com o metal designado de Inox. Para transformar o metal em objetos encomendados pelo cliente, é necessário passar por diversas etapas, sendo estas a etapa corte, dobra, furo, solda, tratamento e acabamento. Contudo a produção de uma encomenda não necessita obrigatoriamente de passar por todas as etapas.

3.2.1 Corte

Etapa de corte (Figura 19) do material é essencial em quase todas as encomendas, sendo esta etapa normalmente a primeira. Os tubos que a empresa adquire do fornecedor têm o comprimento de 6 metros e a empresa necessita de cortar os tubos na medida específica para a produção da uma encomenda.



Figura 19 - Representação da etapa corte

3.2.2 Dobra

Etapa necessária para fabricar alguns objetos onde se dobra uma peça metálica de modo a formar um ângulo (Figura 20). Como exemplo tome-se a construção de um círculo utilizando um tubo para ser utilizado numa mesa-redonda como estrutura para pousar o tampo da mesa.



Figura 20 - Representação da etapa dobra

3.2.3 Furo

Etapa que normalmente é utilizada em todas as encomendas, em que consiste em fazer furos em locais específicos (Figura 21) com o intuito de juntar duas peças, como por exemplo, a junção de duas peças de materiais diferentes (estrutura de inox de uma mesa-redonda com um tampo de madeira para a mesa).



Figura 21- Representação da etapa furo

3.2.4 Solda

Etapa que habitualmente é imprescindível para a produção da encomenda, que consiste na junção de peças que normalmente são do mesmo tipo de material metálico, tornando uma peça única (Figura 22).



Figura 22 - Representação da etapa solda

3.2.5 Tratamento

Etapa que consiste em tratar as faces da encomenda, como por exemplo, tirar o excesso de solda, remover riscos, mossas, entalhes, amassadelas, danos, de modo a prepará-la para a etapa de acabamento (Figura 23).



Figura 23 - Representação da etapa tratamento

3.2.6 Acabamento

Esta etapa que consta no tratamento final da encomenda, tendo como objetivo fazer o acabamento final, de modo a que encomenda fique com o aspeto final desejado pelo cliente (Figura 24).



Figura 24 - Representação da etapa acabamento

3.2.7 Encomendas finalizadas:

Após finalizar a etapa acabamento, a encomenda encontra-se pronta para ser entregue aos clientes. As encomendas produzidas na empresa, podem ser, por exemplo: cadeiras, bases para bilhares, mesas, candeeiros, puxados para portas, bases para cadeirões, pés para sofás, molduras para quadros, rodapés para móveis, entre outros (Figura 25).




Figura 25 - Encomendas finalizadas

3.3 Aplicação de métodos de previsão na indústria

Machine Learning é uma subárea da ciência da computação que se refere a um enorme conjunto de técnicas que visam construir sistemas cujo comportamento é adaptado ao conhecimento existente. Estas técnicas possuem a capacidade de aprender com os seus erros e fazer previsões futuras ou calcular um determinado valor conforme os valores de *input* que são fornecidos [19].

Em [7] foi realizado um estudo para melhorar a gestão de *stock* numa empresa de calçado. O objetivo foi identificar os produtos com maior necessidade de reposição. No trabalho descrito foi utilizada uma rede neuronal composta por quatro camadas intermédias (*hidden layers*) e, segundo os autores, obtiveram-se bons resultados. O sistema desenvolvido teve como objetivo auxiliar o gestor de *stock*, ou seja, trata-se de um sistema de apoio à decisão. Como trabalho futuro, os autores propuseram a inclusão de custos para a fase de treino do algoritmo.

No contexto do agronegócio, em [24] os autores utilizaram uma rede neuronal artificial (*perception*) com o objetivo de fazer previsão dos preços de produtos agrícolas, como por exemplo, soja, milho e trigo. Para que este algoritmo tivesse uma boa previsão, os autores conseguiram dados reais do preço médio mensal de cada produto entre janeiro de 1992 até dezembro de 2006, tendo um total de 168 meses. Após a implementação conseguiram obter bons resultados para a previsão de preço para o mês seguinte dos produtos selecionados, tendo a métrica RMSE valores entre 0,05 e 0,08, R^2 entre 0,80 e 0,92 e MAPE de 0,004 e 0,008. Os autores concluíram que as RNA ajudam bastante na previsão do comportamento dos preços e tomada de decisões.

Num centro de tratamento de encomendas, Ferreira et al. [8] efetuou um estudo com o objetivo de prever o tempo de entrega de diversos produtos. No seu trabalho os autores utilizaram uma Rede Neuronal Artificial do tipo *Multilayer Perceptron* possuindo 12 neurónios de entrada (12 atributos). O *dataset* continha dados de 60 dias e, após fase de treino e validação, os autores aplicaram, na empresa, o modelo desenvolvido durante 15 dias, concluindo que obtiveram bons resultados nas suas previsões. Como trabalho futuro foram identificados novos atributos que serão considerados numa nova estrutura de rede neuronal.

3.4 Gestão de projetos industriais

A gestão de projetos é um conjunto de práticas que visam controlar, executar, organizar e

planear as tarefas do quotidiano de modo que a empresa ou equipa consiga atingir todos os objetivos tendo em consideração um conjunto de restrições associadas. Dentro desta temática podem definir-se projetos ou processos. Um projeto tem como características a geração de um resultado único, elaborado constantemente e de carácter temporário. Um processo tem como características gerar resultados padronizados, definido nas etapas e é contínuo [5].

Um projeto é definido como “empreendimento temporário realizado com o objetivo de produzir um produto ou serviço único” [5]. Para atingir tal definição, os gerentes de projetos devem considerar diferentes áreas de conhecimento e organizacionais para atingir a meta definida para um projeto. De facto, tais tarefas envolvem o planeamento e organização de recursos, tanto humanos quanto físicos (por exemplo, máquinas), a serem alocados e utilizados numa tarefa, evento ou dever específico para cumprir as definições do projeto. Mais recentemente, a gestão de projetos evoluiu e deve ser sustentável, ou seja, “a sustentabilidade garante financeiramente, social e natureza de responsabilidade fatores de aproveitar os recursos e também para oferecer o mesmo para a vinda de futuras gerações ao redor do mundo” [3].

Em [2] os autores aplicaram a gestão de projetos, com o auxílio do guia de conhecimento conhecido como PMBOK, numa empresa do setor metalomecânico que repara e fabrica produtos. Para aumentar a competitividade, a empresa tinha como objetivo melhorar a qualidade da produção dos seus produtos, e para atingir esses objetivos foi necessário investir em recursos humanos e tecnológicos, entre outros. Com a união entre investimento e gestão de projetos, a empresa obteve resultados vantajosos, conseguindo reduzir o prazo de produção e aumentar a qualidade do produto final, atingindo os seus objetivos.

3.5 Casos de estudo

Atualmente, há várias empresas que mantêm a gestão de um processo que não é robusta, e a utilização de metodologias de gestão de projetos é considerada necessária para as empresas, especialmente para as PME [16].

Os níveis inferiores de contabilidade de gestão podem não permitir ao(s) líder(es) da empresa garantir uma grande imagem no mercado, isto é, a principal preocupação é o custo de produção atual, e existe uma resistência em adquirir novas ferramentas de fabrico e, consequentemente, o retorno do investimento a médio ou longo prazo não é considerado. De facto, são várias desvantagens que se mantêm ao longo dos anos, tais como a desorganização no planeamento que leva à execução errada das ordens e,

consequentemente a um incumprimento dos contratos estabelecidos. Existem também outras desvantagens, como perda de tempo no cálculo dos prazos de entrega estimados, baixa produtividade e possível desperdício de matéria-prima devido à má previsão. A principal desvantagem será a insatisfação dos clientes que enfrentam tempo de espera para ter suas necessidades atendidas, ocorrendo principalmente em estações sazonais e tendências que ocorrem todos os anos. Essa falta de compromisso com o cliente pode levar à perda de clientes e resultar em má publicidade, fazendo com que possíveis futuros clientes escolham outras empresas.

Numa empresa de comércio, Edgar Couto [4] concretizou um estudo para a realização de previsões de vendas de modo a melhorar a gestão de *stock*. No seu trabalho o autor utilizou três algoritmos de previsão, nomeadamente o ARIMA - *Autoregressive Integrated Moving Average*, ANN - *Artificial Neural Networks* e o CROSTON. Após validação e verificação de performance concluiu que o algoritmo que apresentou os melhores resultados foi a rede neuronal. O autor comprometeu-se futuramente em utilizar o algoritmo para prever os produtos sobre os quais se devem incidir promoções de modo a estimular as vendas.

Na indústria alimentar, por exemplo, todos os tempos de produção devem ser cumpridos ou a produção pode ser inviável para o consumo. De facto, em [11] definiram-se várias oportunidades para aplicar métodos de IA para reduzir, por exemplo, erros humanos e garantir níveis de qualidade mais elevados, criando um processo de entrega eficiente e, consequentemente, afetando positivamente o sistema de gestão da cadeia de suprimentos.

Na indústria metalúrgica, Shamsuzzoha et. al [15] aplicaram ML e *Deep Learning* para otimizar o processo de deteção do espaço mínimo entre os componentes que foram fabricados após uma operação de perfuração sobre a chapa metálica. O processo automático era um *bottleneck* de produção e que provocava desperdício. Devido aos métodos aplicados a empresa teve como resultado o aumento da produtividade e melhorou a movimentação da máquina de *gripper* (garra utilizada para a perfuração).

Os projetos descritos anteriormente focam-se na aplicação de algoritmos de ML para criar melhores previsões ou definir melhores alocações de recursos. No entanto, as previsões representam parte de um quadro maior, uma vez que as empresas geralmente não produzem um único produto, mas um conjunto de produtos. De facto, essas previsões apenas definiram, por exemplo, o tempo necessário para a produção, e não consideram a inclusão do processo de fabrico na gestão da produção. Uma boa gestão de projetos é também fundamental para garantir que todas as etapas do planeamento ocorram sem

problemas, e sem colisões entre projetos. Nesse sentido, considera-se que cada encomenda corresponde a um projeto. Existem ferramentas específicas para a atividade de gestão de projetos, mas implicam um aumento dos custos de produção devido ao seu custo de aquisição. No entanto, com a sua aplicação, é possível melhorar o foco nos objetivos, nas estratégias adquiridas e realizar todas as etapas necessárias, garantindo maior eficiência no processo a ser realizado.

Para simplificar a gestão, é fundamental que as empresas optem pela metodologia que melhor se adequa ao contexto de cada negócio, de modo a facilitar o controle e agendamento de pedidos. As empresas geralmente precisam coordenar várias solicitações de forma simultânea, e para facilitar a escolha da metodologia, é importante que o responsável tenha um bom conhecimento da área de estudo.

Na gestão de projetos existem várias referências na literatura, sendo o PMBOK - *Project Management Body Knowledge* [5] um dos mais utilizados, pois inclui métodos padronizados das melhores práticas para a preparação correta da estrutura de planeamento.

4. Estudo de Caso

4.1 Apresentação do Estudo de Caso

Em [8] e [2] foram estudados sistemas baseados em Inteligência Artificial [17] que abordam o problema de previsão de tempo de entrega (com a aplicação de redes neurais) ou aplicação de gestão de projetos. No entanto, não foram encontrados artigos (ou outras publicações) que apliquem simultaneamente ambos os sistemas de previsão de encomendas para empresas do setor metalomecânico. Utilizando empresas deste setor como caso de estudo, pretende-se implementar e validar o sistema a desenvolver e, desta forma, aumentar a competitividade, melhorar o planeamento das atividades, aumentar a organização interna e, conseqüentemente, a satisfação do cliente no cumprimento dos prazos estipulados, reduzindo a possibilidade de descumprimento dos compromissos estabelecidos.

Existem vários algoritmos de ML que podem ser usados para prever os tempos de execução de uma determinada tarefa. Regressão Linear Múltipla [12], Redes Neurais Artificiais [1], ou algoritmos de *Deep Learning* como Redes Neurais Convolucionais [10] são alguns algoritmos que podem ser utilizados para tarefas preditivas. No projeto descrito neste documento, e de modo a se obter alguns resultados preliminares, são utilizadas diferentes redes neurais artificiais com o propósito de prever a duração de quanto tempo demora cada etapa para a produção da encomenda.

Para o desenvolvimento da solução proposta é necessário definir várias etapas de modo a validar o progresso e garantir o sucesso do mesmo. Assim, o projeto será dividido nas seguintes fases:

1. Identificação das variáveis necessárias para a caracterização do problema;
2. Aquisição de dados e criação do *dataset*;
3. Desenvolvimento do modelo de *Machine Learning*;
4. Treino e validação do modelo aplicado;
5. Desenvolvimento do módulo para gestão automática de encomendas;
6. Comparação da solução com a realidade.

4.2 Tecnologias utilizadas

4.2.1 *Visual Studio Code*

O projeto contemplou a utilização de diversas ferramentas de modo a facilitar o progresso no sistema operativo *Windows*. Para o ambiente de desenvolvimento usufrui-se do editor de código VSC (*Visual Studio Code*) [48], que tem diversas vantagens como sendo gratuito, *open-source*, multiplataforma, multilinguagem, personalizável, depuração de código e permitir a instalação de múltiplas extensões.

4.2.2 *Pycharm*

Para o desenvolvimento da API em linguagem Python, utilizou-se o IDE (*Integrated Development Environment*) PyCharm [47], trazendo consigo diversas vantagens, de modo a facilitar o desenvolvimento do código, inspeções e deteção de erros em tempo real para auxiliar no controlo de qualidade do código desenvolvido.

4.2.3 *Swagger*

Para conseguir uma boa qualidade e garantia na entrega da REST API é necessário testar cada possível pormenor do resultado do projeto. Para testar uma API é habitual o recurso a algumas ferramentas que facilitam/auxiliam neste processo. A ferramenta selecionada para se proceder a este processo de testes e validação foi o *Swagger*. O *Swagger* [46] é uma ferramenta que aborda todo o ciclo de vida de uma API e inclui uma *interface* de utilizador (IU), em versão *web*, que simplifica a interação com os serviços disponibilizados pela API, ou seja, apresenta de forma visual a informação e permite executar operações específicas. Também oferece a especificação para documentar e descrever a REST API e, devido aos fatores referenciados, tornou-se muito útil e popular na área da informática.

4.2.4 *MongoDB*

Nesta arquitetura foi utilizada para a persistência da informação a base de dados *MongoDB* [45] que é uma base de dados escalável, de alta performance, *open-source*, sem esquemas, e orientado a documentos, ou seja, corresponde a dados sem necessidade de estarem estruturados e que suporta um grande número de linguagens e plataformas de desenvolvimento de aplicações. Por outras palavras é uma base de dados não relacional (*NoSQL*) e suporta o armazenamento de dados no formato de *JSON (JavaScript Object Notation)*. Este tipo de base de dados é utilizada para guardar toda a informação da aplicação, desde os dados que são utilizados para as RNA's fazerem a previsão, treino das

RNA's, resultados dos treinos, informação da empresa, informação necessária para a gestão de projetos. Em suma, toda a informação relativa às diversas etapas que constituem o desenvolvimento deste projeto.

4.2.5 *PyMongo*

PyMongo é uma biblioteca que contém ferramentas que permitem fazer conexão à base de dados MongoDB. Assim foi possível ter acesso aos dados essenciais para o funcionamento do programa.

4.2.6 *Sklearn*

Sklearn é uma biblioteca que permite a implementação de algoritmos de aprendizagem de máquinas em linguagem Python, o que permitiu efetuar a implementação das redes neurais artificiais.

4.2.7 *Pickle*

Pickle é uma biblioteca que permite serialização, ou seja, é um processo de armazenamento de um objeto como um fluxo em bytes ou caracteres, e desserializar uma estrutura de objeto em *Python*. Sendo utilizado para guardar os modelos das RNAs após o treino e para carregar o modelo sempre que fosse necessário.

4.2.8 *Pandas*

Pandas é uma biblioteca que permite a manipulação e análise de dados, permitindo a importação de dados em diferentes formatos como csv, txt, entre outros, para a leitura em *dataframes*.

4.2.9 *Numpy*

Numpy é uma biblioteca que suporta o processamento de grandes dados com suporte para matrizes e como uma vasta operação de funções matemáticas.

4.2.10 *Python*

Python [44] é uma linguagem de programação de alto nível, *open-source*, orientada a objetos, funcional e com muitas potencialidades a serem exploradas [22]. É de fácil aprendizagem e a sua sintaxe é relativamente simples, corre em qualquer sistema operativo.

4.2.11 *Angular*

Para que os utilizadores consumam os recursos do *back-end* de forma relativamente fácil e intuitiva, ou seja, para que consigam ter uma boa experiência, foram criados documentos com a capacidade de serem visualizados num navegador *web*. Esses documentos são designados por páginas *web*, geralmente, desenvolvidos com linguagem HTML, a qual é interpretada pelos navegadores e podem apresentar diversos conteúdos em diferentes formatos como texto, imagens, sons e vídeos.

Para o desenvolvimento de um projeto *web*, o ideal não é a construção da solução a partir do zero, devido às desvantagens que isso poderá provocar, ou seja, ficava um projeto muito demorado e com custo elevado. Para os problemas que são abundantemente populares no progresso de um projeto *web*, normalmente é utilizado uma *framework* de modo a facilitar o seu desenvolvimento.

As *frameworks* são plataformas que disponibilizam um conjunto de bibliotecas ou componentes que auxiliam no desenvolvimento, tornando-o num processo mais célere. Têm como vantagens a manutenção do código, documentação e materiais online, eficiência, custo, qualidade do código, usabilidade, segurança e tempo de desenvolvimento.

Para o desenvolvimento deste projeto, utilizou-se a *framework open-source Angular* [43], plataforma para construção de interfaces de utilizador (UI – *User Interface*), utilizando as linguagens HTML, LESS e TS (TypeScript). O TypeScript é um superconjunto do JavaScript desenvolvido pela Microsoft e traz diversas vantagens como ser orientado a objetos e declaração dos tipos de dados.

Com a *framework Angular* é esperado ter uma maior facilidade na criação de páginas e reutilização de código, uma vez que a programação é feita através de componentes, e esses componentes podem ser reutilizados noutros componentes, incluindo no componente principal. Para facilitar no design das páginas *web* foi utilizado a *framework Bootstrap*, que auxiliou o desenvolvimento de um site com um melhor aspeto e responsivo.

4.3 Arquitetura

Para o desenvolvimento do projeto pretende-se a implementação da arquitetura ilustrada na Figura 26 - Arquitetura. Esta encontra-se dividida em dois módulos, o *front-end* e o *back-end*.

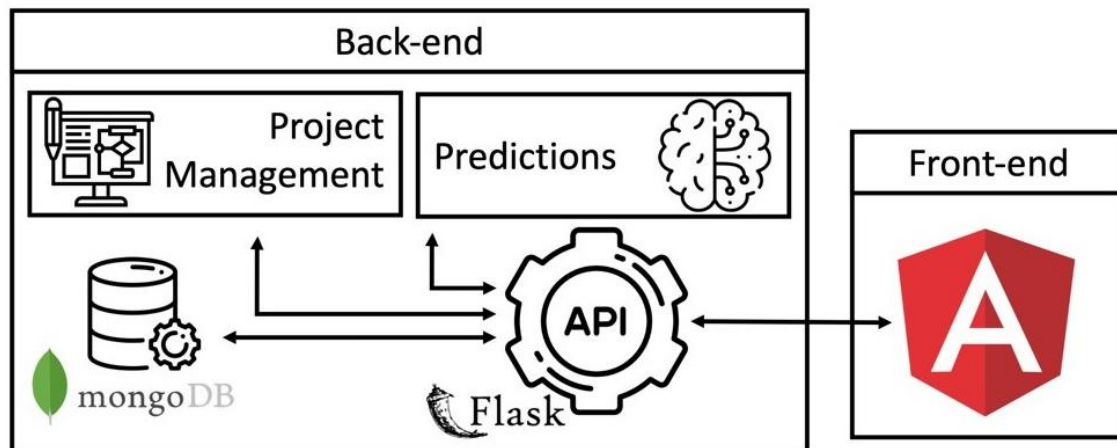


Figura 26 - Arquitetura

O *front-end* será desenvolvido com recurso à *framework* Angular [43], implementado de modo que seja possível consumir os recursos disponibilizados pelo *back-end*. Neste componente será desenvolvida a interface do utilizador de modo a permitir a visualização, tanto das previsões realizadas como do escalonamento das diversas etapas dos variados projetos. Terá também a possibilidade de permitir a introdução de informação por parte do utilizador de modo a, se necessário, ajustar planeamentos. O *back-end* engloba uma API (*Application Programming Interface*) em linguagem Python, desenvolvida utilizando a *framework* Flask [50] em conjunto com o Swagger [46], que possibilita a documentação e realização de pedidos REST (*Representational State Transfer*) sem a necessidade de possuir o *front-end*.

No *back-end* serão incluídos os módulos de *Machine Learning* para permitir o treino e criação de um modelo para previsão, uma base de dados em MongoDB [45] para preservar toda a informação necessária à sua execução, e um módulo para a gestão de projetos para validação e alocação das etapas de produção.

O algoritmo de previsão será treinado de forma diária de modo a garantir que as previsões realizadas sejam com base nos dados mais recentes.

4.4 Back-end

4.4.1 Dataset

Numa fase inicial, o *dataset* foi gerado com 200 linhas de dados sintéticos para que seja possível efetuar o treino do modelo de *Machine Learning* previamente selecionado para as empresas do setor de metalomecânica. Esta geração também permite reunir, em paralelo, dados reais. De facto, o processo para testar novos resultados torna-se mais rápido, pois é

mais fácil trocar dados gerados por dados reais no modelo treinado.

Atualmente o *dataset* para a algoritmo é composto por 26 variáveis de entrada, sendo 2 variáveis do tipo categórico e 24 variáveis do tipo numérico. Como resultado do modelo, pretende-se obter a previsão de tempo de cada etapa necessária para se fabricar o objeto.

Na tabela 1, apresentam-se os atributos que serão considerados e o seu respetivo tipo.

Tabela 1 - Variáveis e tipo de dados

Nome das variáveis	Etapa	Descrição	Tipo de variável
Número de funcionários	Corte	Número de funcionários da empresa destinada a etapa corte	Numérico
Número de máquinas	Corte	Número de máquinas da empresa destinada a etapa corte	Numérico
Número simples	Corte	Número de cortes simples	Numérico
Número complexos	Corte	Número de cortes complexas	Numérico
Previsão	Corte	Previsão da duração	Numérico
Número de funcionários	Dobra	Número de funcionários da empresa destinada a etapa dobra	Numérico
Número de máquinas	Dobra	Número de máquinas da empresa destinada a etapa dobra	Numérico
Número simples	Dobra	Número de dobras simples	Numérico
Número complexos	Dobra	Número de dobras complexas	Numérico
Previsão	Dobra	Previsão da duração	Numérico
Número de funcionários	Furo	Número de funcionários da empresa destinada a etapa furo	Numérico

Número de máquinas	Furo	Número de máquinas da empresa destinada a etapa furo	Numérico
Número simples	Furo	Número de furos simples	Numérico
Número complexos	Furo	Número de furos complexas	Numérico
Previsão	Furo	Previsão da duração	Numérico
Número de funcionários	Solda	Número de funcionários da empresa destinada a etapa solda	Numérico
Número de máquinas	Solda	Número de máquinas da empresa destinada a etapa solda	Numérico
Número simples	Solda	Número de soldas simples	Numérico
Número complexos	Solda	Número de soldas complexas	Numérico
Previsão	Solda	Previsão da duração	Numérico
Número de funcionários	Tratamento	Número de funcionários da empresa destinada a etapa tratamento	Numérico
Número de máquinas	Tratamento	Número de máquinas da empresa destinada a etapa tratamento	Numérico
Número simples	Tratamento	Número de faces simples para tratamento	Numérico
Número complexos	Tratamento	Número de faces complexas para tratamento	Numérico
Previsão	Tratamento	Previsão da duração	Numérico
Número de funcionários	Acabamento	Número de funcionários da empresa destinada a etapa acabamento	Numérico
Número de máquinas	Acabamento	Número de máquinas da empresa destinada a etapa acabamento	Numérico

Número simples	Acabamento	Número de faces simples para acabamento	Numérico
Número complexos	Acabamento	Número de faces complexas para acabamento	Numérico
Tipo Acabamento	Acabamento	Tipo de acabamento do objeto (polido ou escovado)	Categórico
Tipo Limpeza	Acabamento	Dificuldade do tipo de limpeza do objeto (fácil, médio ou rigoroso)	Categórico
Previsão	Acabamento	Previsão da duração	Numérico

O objetivo é determinar automaticamente o tempo estimado para cada etapa. As variáveis selecionadas foram escolhidas como sendo as mais representativas das atividades executadas numa empresa metalomecânica (utilizada como estudo de caso). Com efeito, para cada etapa da fabricação de um produto existem várias etapas sequenciais que devem ser realizadas no metal para atingir o estado final desejado. Ao utilizar uma pequena empresa portuguesa como caso de estudo, os dados são recolhidos de forma a não haver necessidade de os processar posteriormente. Com efeito, os valores recolhidos são obtidos através de questionários aos colaboradores. Devido à pequena quantidade de dados, novos dados foram sintéticos considerando a média e o desvio padrão para cada variável. Variáveis categóricas foram convertidas com recurso à função de *One Hot Encoder* disponibilizado na biblioteca *scikit-learn* [49].

4.4.2 Algoritmo de *Machine Learning*

O projeto foi dividido em duas fases principais:

1. Desenvolvimento do modelo de previsão;
2. Implementação de um sistema de gestão de projetos.

Para a primeira fase realizou-se a criação do *dataset* segundo as variáveis identificadas e utilização dos dados recolhidos numa rede neuronal artificial de modo a obter uma previsão mais precisa do tempo necessário para realizar cada etapa necessária para a produção de objetos em empresas do setor metalomecânico, mais especificamente em Serralharias.

Após a criação do *dataset* foi necessário verificar se os dados obtidos necessitavam de ser tratados de modo a ser possível utilizar no algoritmo de ML, ou seja, efetuar uma limpeza de variáveis e conseqüentemente a criação de novos atributos de acordo com a lógica de negócio. De seguida procedeu-se à divisão dos dados para se proceder ao treino do

modelo, utilizando 20% dos dados para teste e 80% dos dados para treino, para posteriormente conduzir a validação do modelo, como se pode verificar na Figura 27 – Processo de treino do modelo.




Figura 27 – Processo de treino do modelo

Para implementar uma rede neuronal multicamada (MLP – *MultiLayer Perceptron*), utilizou-se o construtor da biblioteca *scikit-learn* no qual podem ser configurados diversos parâmetros. Cada parâmetro tem seu valor padrão, de modo que é possível criar uma rede MLP sem precisar definir nenhum deles. Existem pelos menos dois construtores possíveis quando é utilizado a biblioteca referida anteriormente (*sklearn.neural_network*), sendo o *MLPClassifier* utilizado para problemas de classificação e o *MLPRegressor* que é utilizado para problemas de regressão. Como este caso de estudo tem como objetivo fazer a previsão de um valor, ou seja, determinar quanto tempo irá demorar uma determinada etapa de fabrico daquela encomenda, está-se perante um problema de regressão (*MLPRegressor*). Alguns parâmetros de alto impacto foram ajustados e as configurações desses parâmetros estão apresentadas na tabela 2. Após cada treino, cujo tempo de computação é elevado devido ao tamanho da base de dados, é necessário guardar o modelo treinado para que no futuro ao utilizar novos dados para a previsão não seja obrigatório efetuar novamente o treino. Por este motivo é utilizada a biblioteca “pickle” que permite guardar um modelo treinado e posteriormente, quando for necessário prever novos valores, é possível ler e utilizar o modelo previamente treinado.

Tabela 2 - Configurações testadas para treino da rede

Camadas Ocultas	200; 150; 100;50
Tolerância	0.0000001
Função de ativação	relu
Solver	sgd
Taxa de aprendizagem inicial	0.1
Taxa de aprendizagem adaptável	constant
Número máximo de épocas	500

Para prever todas as etapas foram implementadas, no total, 12 RNA's, tendo 6 RNA's com variável dependente o número de funcionários de cada etapa e 6 RNA's com variável dependente o número de máquinas que a empresa possui para cada etapa.

Após treino das RNA's procedeu-se ao ajuste de hiperparâmetros de modo a melhorar a *performance* da rede. Entre os hiperparâmetros estudados estão o número de camadas intermédias diferentes (tanto em número de unidades por camadas, como de camadas em si), taxa de aprendizagem, entre outros. Como resultado da fase de treino e teste/validação, obtiveram bons resultados sendo a estrutura da rede e as métricas de *performance* obtidas apresentadas na Tabela 3 - Resultados 3.

Após treino e validação dos modelos desenvolvidos, foram calculadas as métricas de *performance*, RMSE e MAE, de modo a se proceder à sua avaliação. Em função dos valores obtidos poder-se-á atestar a qualidade do modelo ou a necessidade de alterar hiperparâmetros de modo a evitar possíveis situações de *overfitting/underfitting*. Na tabela 3 apresentam-se, de forma detalhada, os resultados obtidos, considerando os melhores treinos e tendo, também em consideração, os dados utilizados (que foram gerados e, por este motivo, tentam representar da forma mais fidedigna possível a realidade).

Assim, verifica-se que algumas RNA's obtiveram bons resultados, apresentando valores inferiores a 1 para as métricas selecionadas, ou seja, o resultado da previsão foi corretamente generalizado após o treino.

Considerando a métricas, observa-se que algumas previsões tiveram bons resultados com capacidade de prever quanto tempo que a etapa iria demorar na realidade.

Tabela 3 - Resultados

RNA	Etapa	Test MAE	Test RMSE	Train MAE	Train RMSE
Funcionário	Corte	0.45	0.72	0.52	0.72
Máquina	Corte	0.65	0.81	0.73	0.73
Funcionário	Dobra	0.55	0.62	0.39	0.62
Máquina	Dobra	0.25	0.75	0.57	0.75
Funcionário	Furo	0.35	0.71	0.50	0.71
Máquina	Furo	0.30	0.71	0.50	0.35
Funcionário	Solda	0.40	0.77	0.60	0.77
Máquina	Solda	0.55	0.70	0.49	0.70
Funcionário	Tratamento	0.50	0.72	0.51	0.72
Máquina	Tratamento	0.85	1.23	0.99	1.23
Funcionário	Acabamento	0.55	0.75	0.56	0.75
Máquina	Acabamento	0.40	0.72	0.52	0.72

Com uma previsão de boa qualidade, o projeto passou para a segunda fase onde se pretendia gerar a programação dos vários processos com a respetiva precedência, de forma a ajustar, organizar e otimizar as etapas de produção das encomendas para que a empresa pode produzir vários pedidos simultaneamente da melhor maneira.

O objetivo foi o desenvolvimento de um planeamento semanal que, de acordo com necessidades mais específicas, permite ajustes sem prejuízo nos prazos de entrega inicialmente definidos.

Para avaliação do algoritmo foi utilizado a estatística de avaliação o desvio padrão, Tabela 4, entende-se que os modelos de regressão indicam uma elevada uniformidade entre os dados (quanto mais próximo do zero, melhor o resultado).

Tabela 4 - Desvio Padrão

Etapas	RNA - Funcionário	RNA - Máquina
Corte	0.15	0.11
Furo	0.14	0.10
Dobra	0.14	0.14
Solda	0.10	0.12
Tratamento	0.13	0.21
Acabamento	0.25	0.10

4.4.3 Gestão de projetos

A GP atualmente é conhecida como um processo de gestão de negócios, portanto é esperado que os gestores dos projetos tomem as decisões mais corretas possíveis de maneira a alcançar a qualidade e experiência necessária na gestão e boas práticas para que a empresa consiga responder ao máximo de encomendas possíveis, beneficiando com o aumento de produção, gestão, organização com o propósito de sobrevivência da empresa no mundo dos negócios. Este projeto possui uma ferramenta de TI (Tecnologia de informação) que possibilita a integração de métodos de GP, de modo a auxiliar o gestor nos processos e planeamento das encomendas.

Esta ferramenta foi desenvolvida com base na localização da empresa que irá utilizar esta tecnologia. Devido a esse fator geográfico e às regras laborais que se encontram legisladas, foram desenvolvidas regras automáticas que auxiliam o gestor durante a adição de novas etapas como, por exemplo:

- Exclusão das datas correspondentes aos fim-de-semanas de Portugal;
- Exclusão das datas correspondentes a feriados e dias santos de Portugal;
- Horário de trabalho da empresa;
- Número total de funcionários por setor;
- Número total de máquinas por setor.

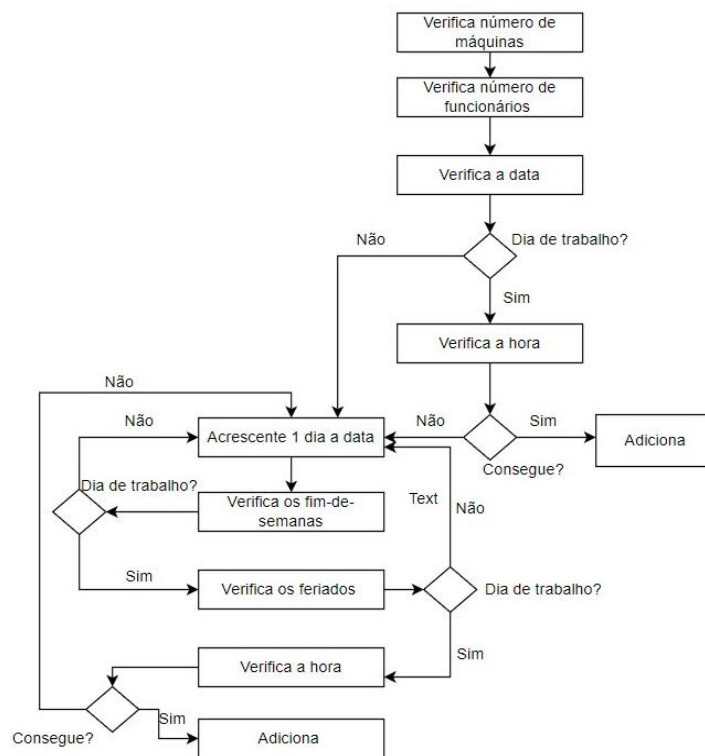


Figura 28 - Fluxo da GP

Em virtude destas circunstâncias, Figura 28, os mecanismos de GP irão definir qual a melhor opção durante a inserção de uma etapa no processo produtivo, trazendo benefícios para o utilizador. Desta forma o gestor não precisa de se preocupar quando poderá iniciar a produção, se tem máquinas ou funcionários disponíveis e em que dias acontece a produção.

Considerando a empresa utilizada como caso de estudo estudou-se o processo de receção de novas encomendas. Neste caso, após obter os dados da encomenda procedeu-se à previsão do tempo de execução de cada etapa com base nas RNA's treinadas para determinar o tempo total de execução da encomenda. Com base nesta informação o gestor pode, por um lado, otimizar a produção e ajustar os prazos de entrega a contratualizar com o cliente. Deste modo é fornecido ao gestor a informação descrita na tabela 4.

Tabela 5 - Gestão de projetos

Nome das variáveis	Descrição	Tipo de variável
Nome	Nome do projeto	Categórico
Etapa	Identificação de etapa	Categórico
Data	Data de registo de quando foi feito a previsão	Numérico
Previsão	Previsão da duração da etapa	Numérico
Data Inicial	Data em que a etapa será iniciada	Numérico
Data Final	Data em que a etapa será terminada	Numérico
Hora Inicial	Hora em que a etapa será iniciada	Numérico
Hora Final	Hora em que a etapa será finalizada	Numérico
Gráfico	Variável que informa se a etapa já foi utilizada no gráfico (0-não utilizada, 1-utilizada)	Numérico
Resultado Real	Variável que informa quanto tempo demorou, em minutos, a etapa na realidade.	Numérico

Caso se formalize o contrato, o gestor pode acionar o plano de fabrico, adicionando ao gráfico de planeamento todas as etapas da encomenda, da forma mais benéfica possível para a produção. Esta adição cumpre com os requisitos associados à GP onde se verifica de forma automática a não colisão de etapas de fabrico com outros projetos, garantia de execução sequencial de etapas, entre outros.

4.4.4 Cronjob

Este processo tem como objetivo ser executado automaticamente a cada dia às 23 horas, horário que normalmente a empresa se encontra encerrada, de maneira que realize um novo treino com os novos dados de todas as 12 RNA's.

Como se verifica na Figura 29 - Esquema do *Cronjob*, tem como objetivo efetuar um novo treino de todas as RNAs com os novos dados que são obtidos ao longo do dia de trabalho, assim o modelo estará mais apto a realizar a previsão para ser utilizado no dia seguinte. O novo modelo será utilizado para prever os novos dados que posteriormente serão também utilizados na gestão de projetos.

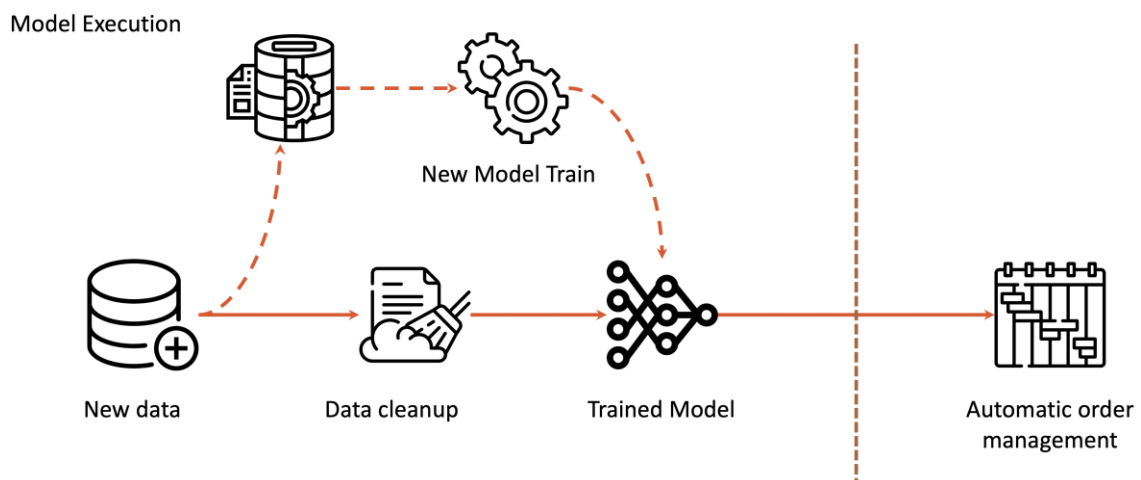


Figura 29 - Esquema do *Cronjob*

4.4.5 Swagger

Para testar os serviços, foi implementado uma ferramenta que aborda todo o ciclo de vida da *API* e inclui uma interface de utilizador (UI), em versão *WEB*, que simplifica a interação com os serviços disponibilizados, ou seja, apresenta visualmente a informação e permite executar operações específicas. É também possível documentar e descrever cada operação.

O *swagger* está dividido em 4 grupos, de modo a organizar as operações da *API*. O primeiro grupo está associado aos métodos que permitem visualizar os registos guardados na base de dados, como se pode verificar na Figura 30 - Visualização dos registos. Neste grupo de pedidos incluem-se, por exemplo, funcionalidades para obter informação sobre os acabamentos disponíveis, tipos de dobras, entre outros.

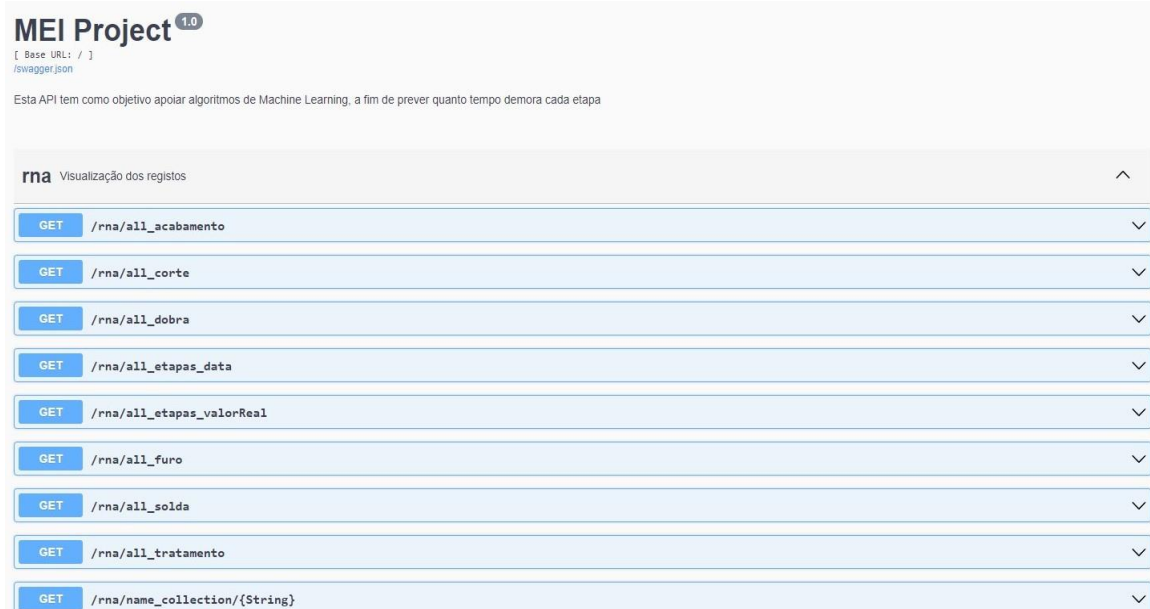


Figura 30 - Visualização dos registos

Este grupo tem os *endpoints* REST responsáveis para a visualização dos dados. Na tabela 5 encontram-se detalhados os *endpoints* disponíveis.

Tabela 6 - *Endpoints* de visualizado de registos

Ação	EndPoint	Descrição
GET	/rna/all_acabamento	Permite obter todos os registos da etapa acabamento.
GET	/rna/all_corte	Permite obter todos os registos da etapa corte.
GET	/rna/all_dobra	Permite obter todos os registos da etapa dobra.
GET	/rna/all_etapas_data	Permite obter todos os registos de todas as etapas que já foram e estão a ser utilizadas no gráfico da gestão de projetos.
GET	/rna/all_etapas_valorReal	Permite obter todos os registos de todas as etapas que já possui o valor real que demorou na realidade.

GET	/rna/all_furo	Permite obter todos os registos da etapa furo
GET	/rna/all_solda	Permite obter todos os registos da etapa solda
GET	/rna/all_tratamento	Permite obter todos os registos da etapa tratamento
GET	/rna/name_collection/{String}	Permite obter todos os registos dependentemente do parâmetro <i>String</i> (exemplo: Empresa, Corte)

O grupo 2 está associado aos métodos cujo objetivo é a manipulação do gráfico de gestão de projetos. Através do *Swagger*, os endpoints podem ser acedidos de acordo com a informação detalhada na Figura 31 - Métodos do gráfico.




Figura 31 - Métodos do gráfico

Neste grupo os *endpoints* REST são responsáveis pelos métodos relacionados à manipulação do gráfico, encontrando-se detalhados na tabela 6.

Tabela 7 - *Endpoints* do gráfico

Ação	Endpoint	Descrição
PUT	/grafico/add_grafico/{id}/ {Etapa}	Permite atualizar as informações, de modo, a ativar a adicionar a etapa ao gráfico. Recebe como parâmetros a informação necessária para identificar a etapa escolhida.
PUT	/grafico/add_resultado/{ Etapa}/{id}/{resultado}	Permite atualizar as informações, de maneira a atualizar o valor real do tempo que demorou, em minutos, a etapa na realidade. Recebe como parâmetro a informação necessária para identificar a etapa que deve ser atualizada.

O grupo 3 possui os métodos associados ao controlo da empresa como, por exemplo, editar informação sobre a mesma (Figura 32 - Métodos de empresa).

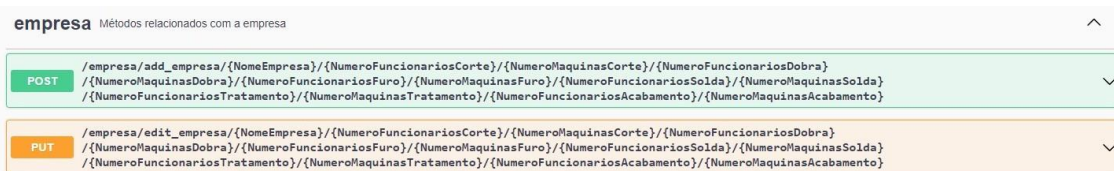


Figura 32 - Métodos de empresa

Este grupo contém dois *endpoints* REST que permitem editar e/ou adicionar dados relacionados com as características da empresa. A tabela 7 e tabela 8 apresentam, de forma detalhada, a estrutura destes *endpoints*.

Tabela 8 - *Endpoint Post* relacionado a empresa

Ação	POST
Endpoint	<code>/empresa/add_empresa/{NomeEmpresa}/{NumeroFuncionariosCorte}/{NumeroMaquinasCorte}/{NumeroFuncionariosDobra}/{NumeroMaquinasDobra}/{NumeroFuncionariosFuro}/{NumeroMaquinasFuro}/{NumeroFuncionariosSolda}/{NumeroMaquinasSolda}/{NumeroFuncionariosTratamento}/{NumeroMaquinasTratamento}/{NumeroFuncionariosAcabamento}/{NumeroMaquinasAcabamento}</code>
Descrição	Permite adicionar um novo registo com as informações da empresa.

Tabela 9 - *Endpoint Put* relacionado a empresa

Ação	PUT
Endpoint	<code>/empresa/edit_empresa/{NomeEmpresa}/{NumeroFuncionariosCorte}/{NumeroMaquinasCorte}/{NumeroFuncionariosDobra}/{NumeroMaquinasDobra}/{NumeroFuncionariosFuro}/{NumeroMaquinasFuro}/{NumeroFuncionariosSolda}/{NumeroMaquinasSolda}/{NumeroFuncionariosTratamento}/{NumeroMaquinasTratamento}/{NumeroFuncionariosAcabamento}/{NumeroMaquinasAcabamento}</code>
Descrição	Permite atualizar a informação da empresa.

O quarto grupo engloba todos os métodos necessários à realização da previsão de quanto tempo irá demorar cada etapa de produção da encomenda, como se pode verificar na Figura 33 - Grupo de métodos para previsão.

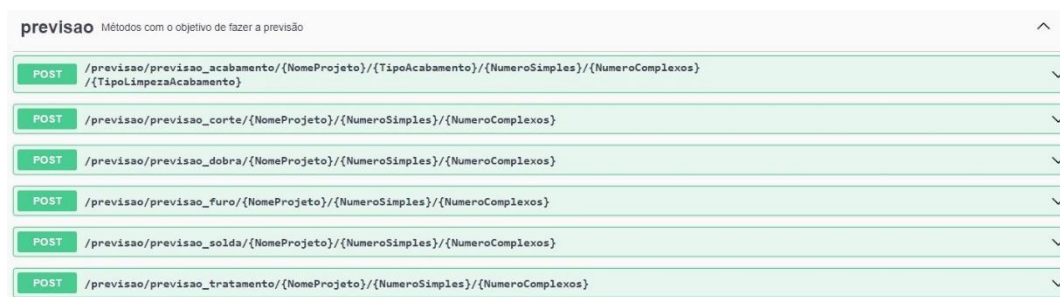


Figura 33 - Grupo de métodos para previsão

Neste grupo incluem-se os *endpoints* REST responsáveis métodos relacionados com a previsão, encontrando-se apresentados com maior detalhe na tabela 9.

Tabela 10 - *Endpoints* relacionados a previsão

Ação	Endpoint	Descrição
POST	<code>/previsao/previsao_acabamento/{NomeProjeto}/{TipoAcabamento}/{NumeroSimples}/{NumeroComplexos}/{TipoLimpezaAcabamento}</code>	Permite adicionar um novo registo com as informações da etapa de acabamento e com a previsão do tempo que irá demorar.
POST	<code>/previsao/previsao_corte/{NomeProjeto}/{NumeroSimples}/{NumeroComplexos}</code>	Permite adicionar um novo registo com as informações da etapa de corte e com a previsão do tempo que irá demorar.
POST	<code>/previsao/previsao_dobra/{NomeProjeto}/{NumeroSimples}/{NumeroComplexos}</code>	Permite adicionar um novo registo com as informações da etapa de dobra e com a previsão do tempo que irá demorar.
POST	<code>/previsao/previsao_furo/{NomeProjeto}/{NumeroSimples}/{NumeroComplexos}</code>	Permite adicionar um novo registo com as informações da etapa de furo e com a previsão do tempo que irá demorar.

POST	/previsao/previsao_solda/{NomeProjeto}/{NumeroSimples}/{NumeroComplexos}	Permite adicionar um novo registo com as informações da etapa de solda e com a previsão do tempo que irá demorar.
POST	/previsao/previsao_tratamento/{NomeProjeto}/{NumeroSimples}/{NumeroComplexos}	Permite adicionar um novo registo com as informações da etapa de tratamento e com a previsão do tempo que irá demorar.

4.5 Front-end

Para facilitar o consumo dos *endpoints* da *REST API*, foi desenvolvido um *front-end* utilizando a *framework Angular*. A utilização desta *Framework* permitiu a criação e reutilização de código, uma vez que esta permite a criação de componentes. Estes podem, por sua vez, ser utilizados múltiplas vezes dentro de outros componentes ou dentro do componente principal.

Para o *design* das páginas *web* foi utilizado-se a *framework Bootstrap*, permitindo não só trabalhar o aspecto visual da aplicação desenvolvida, como verificar outras características como responsividade (exemplo, adaptação a múltiplos ecrãs) e intuitivo de modo a facilitar a interpretação da informação disponibilizada ao gestor. A aplicação comunica com a *API* desenvolvida em linguagem *Python* através de pedidos *HTTP*.

O fluxo deste projeto consiste obrigatoriamente em fazer um registo de uma empresa, Figura 42 - UI - Adicionar empresa, ou alterar/atualizar a informação, Figura 43 - UI - Alteração da empresa. Nesta etapa inicial é necessário introduzir um conjunto de dados específicos da empresa como, por exemplo, nome e outros dados como, por exemplo, processos existentes, número de máquinas disponíveis e número de colaboradores associados a cada processo. A tabela 10 apresenta o conjunto de dados necessário para serem posteriormente fornecidos às RNA's. A Figura 34 – UI – Empresa apresenta o resultado final da página web desenvolvida.

Tabela 11 - Dados da empresa

Nome das variáveis	Etapa	Descrição	Tipo da variável
--------------------	-------	-----------	------------------

Nome	-	Nome da empresa	Categórico
Data	-	Data de registo da empresa	Numérico
Número Funcionários	Corte	Número de funcionários da empresa destinada a etapa corte	Numérico
Número Máquinas	Corte	Número de máquinas da empresa destinada a etapa corte	Numérico
Número Funcionários	Dobra	Número de funcionários da empresa destinada a etapa dobra	Numérico
Número Máquinas	Dobra	Número de máquinas da empresa destinada a etapa dobra	Numérico
Número Funcionários	Furo	Número de funcionários da empresa destinada a etapa furo	Numérico
Número Máquinas	Furo	Número de máquinas da empresa destinada a etapa furo	Numérico
Número Funcionários	Solda	Número de funcionários da empresa destinada a etapa solda	Numérico
Número Máquinas	Solda	Número de máquinas da empresa destinada a etapa solda	Numérico
Número Funcionários	Tratamento	Número de funcionários da empresa destinada a etapa tratamento	Numérico
Número Máquinas	Tratamento	Número de máquinas da empresa destinada a etapa tratamento	Numérico
Número Funcionários	Acabamento	Número de funcionários da empresa destinada a etapa acabamento	Numérico
Número	Acabamento	Número de máquinas da	Numérico

Máquinas		empresa destinada a etapa acabamento	
----------	--	--------------------------------------	--

Empresa

Adicionar Empresa

Id	1
Nome	Serralharia
Data de registo	Tue, 27 Sep 2022 19:47:35 GMT
Número Funcionarios Acabamento	2
Número Máquinas Acabamento	2
Número Funcionarios Corte	1
Número Máquinas Corte	2
Número Funcionarios Dobra	1
Número Máquinas Dobra	3
Número Funcionarios Furo	2
Número Máquinas Furo	2
Número Funcionarios Solda	1
Número Máquinas Solda	2
Número Funcionarios Tratamento	1
Número Máquinas Tratamento	2

Editar Empresa

Figura 34 – UI – Empresa

Assim o utilizador não necessita esta sempre a mesma informação sempre que necessitar de efetuar a previsão de uma determinada etapa (Figura 35), tendo apenas de preencher o formulário para fazer a previsão (Figura 37). Contudo, sempre que os dados tiverem desatualizados o utilizador tem a opção de atualizar os dados. Por este motivo a informação pode mudar.

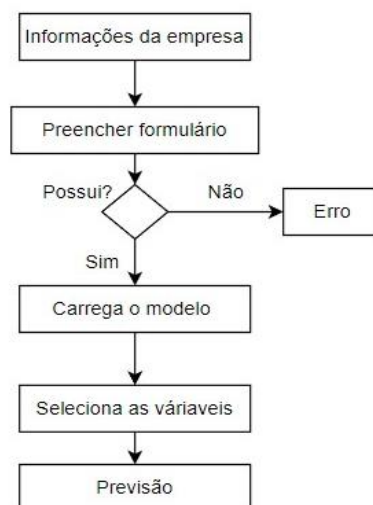


Figura 35 - Informações da empresa

De modo a diminuir ao máximo a introdução de dados manuais pelo gestor, desenvolveu-se a interface de utilizador apresentada na Figura 36 - UI - Lista de etapas para previsões, que permite a seleção/indicação da etapa para a qual se pretende realizar a previsão do seu tempo de execução. A seleção da etapa que se pretende prever conduz o utilizador para um novo formulário pré-preenchido onde se permite possíveis alterações à informação existente (ver Figura 44 - UI – Formulário de previsão da etapa de corte, Figura 45 - UI - Formulário de previsão da etapa de dobra, Figura 46 - UI - Formulário de previsão da etapa de solda, Figura 47 - UI - Formulário de previsão da etapa de furo, Figura 48 - UI - Formulário de previsão da etapa de tratamento, em apêndice)

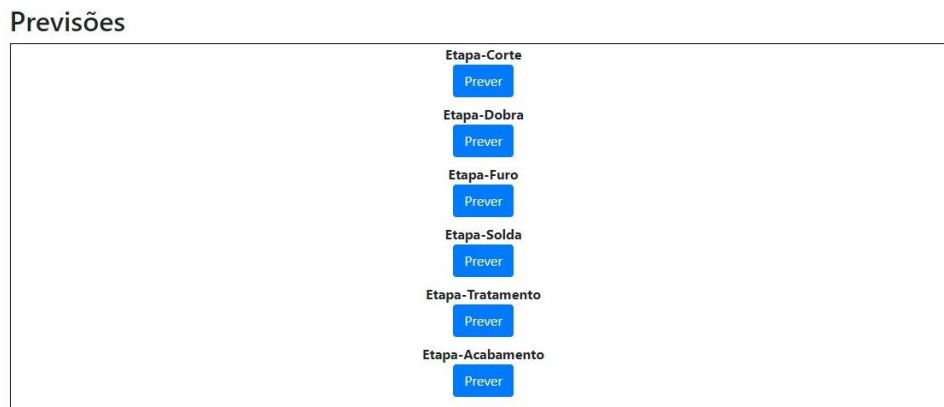


Figura 36 - UI - Lista de etapas para previsões

O processo anterior é comum às diferentes etapas, com exceção da etapa de acabamento. De um modo geral esta é considerada a última etapa de qualquer projeto/encomenda e, devido às suas características, existem dois novos campos para configurar: tipo de acabamento e tipo de limpeza. Como acabamento pode ser selecionado polido ou escovado e o campo de limpeza refere o grau de dificuldade que este último passo necessita, variando entre simples e rigoroso. Na Figura 37 - UI - Formulário de previsão da etapa de acabamento apresenta-se a interface desenvolvida para este processo.

Previsão Acabamento

Name:

Tipo Acabamento:

Número Simples:

Número Complexos:

Tipo Limpeza:

Figura 37 - UI - Formulário de previsão da etapa de acabamento

Após concretizar a previsão das etapas necessárias para realizar a produção da encomenda do cliente, o gestor terá acesso à lista de etapas previstas (Figura 49 - Lista de etapas previstas), onde terá de indicar a ordem de execução das etapas. A definição desta ordem provoca a adição de cada etapa ao gráfico da gestão de projetos no qual o *software* considera colisões com outros projetos que se encontram em execução. Previamente à inserção da tarefa no gráfico de gestão de projetos, é permitido ao gestor visualizar toda a informação referente à etapa. A Figura 38 - UI - Previsão da etapa corte apresenta um exemplo para a etapa de corte. As restantes etapas apresentam-se na Figura 51 - UI - Previsão da etapa dobra ,Figura 50 - UI - Previsão da etapa furo, Figura 52 - UI - Previsão da etapa solda, Figura 53 - UI - Previsão da etapa tratamento, Figura 54 - UI - Previsão da etapa acabamento, em apêndice.

Adicionar a gestão de projetos

Id	Nome	Etapa	Data de Registo	Numero Simples	Numero Complexos	Previsao
1	Projeto 1	Corte	Tue, 27 Sep 2022 19:56:33 GMT	5	10	2:20:56.134 <input type="button" value="Adicionar"/>

Figura 38 - UI - Previsão da etapa corte

A visualização gráfica da informação (etapas inseridas no processo produtivo) permite uma organização simplificada e visual. Este método de apresentação permite a aumentar a capacidade de resposta e, conseqüentemente, da capacidade de produção. A Figura 39 - UI - Gestão de projetos apresenta o gráfico com as etapas produtivas para dois projetos em simultâneo. Neste é possível identificar o início e fim de cada atividade, observando-se apenas as etapas ativas ou futuras.

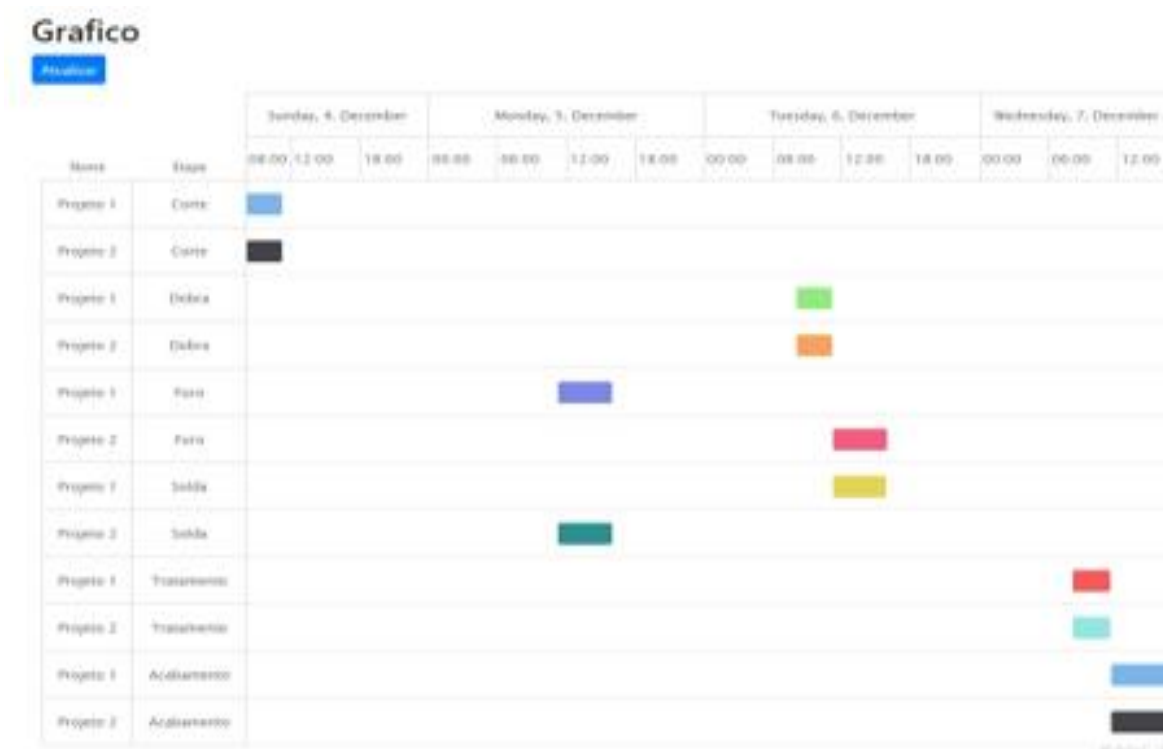


Figura 39 - UI - Gestão de projetos

Em caso de necessidade é possível alterar o método de visualização gráfico para o formato de tabela onde se possibilita verificar informação mais detalhada das etapas ativas. Na Figura 40 - UI - Informação das etapas ativadas

De modo a se extrair informação mais correta sobre o tempo total que uma determinada etapa demorou efetivamente a ser realizada, o funcionário da empresa deve informar o gestor de projetos para que este possa atualizar o sistema. Estes novos dados são posteriormente utilizados para desenvolver novos modelos com informação real (em substituição da informação inicialmente gerada). Na Figura 28 - UI - Informação das etapas

ativas apresenta-se a página desenvolvida para permitir a inserção dos valores reais de execução.

Lista de etapas ativas

Id	Nome	Etapa	Data de Registro	Data da etapa	Numero Simples	Numero Complexos	Tipo Limpeza	Tipo Acabamento	Valor Previsto	
2	Projeto 2	Furo	Tue, 27 Sep 2022 20:06:37 GMT	Wed, 28 Sep 2022 00:00:00 GMT	4	4			2:06:14.484	Add
2	Projeto 2	Solda	Tue, 27 Sep 2022 20:07:07 GMT	Wed, 28 Sep 2022 00:00:00 GMT	6	3			2:07:07.234	Add
1	Projeto 1	Tratamento	Tue, 27 Sep 2022 19:58:37 GMT	Wed, 28 Sep 2022 00:00:00 GMT	1	16			3:23:34.374	Add
2	Projeto 2	Tratamento	Tue, 27 Sep 2022 20:07:21 GMT	Wed, 28 Sep 2022 00:00:00 GMT	5	5			2:23:17.738	Add
1	Projeto 1	Acabamento	Tue, 27 Sep 2022 19:59:32 GMT	Wed, 28 Sep 2022 00:00:00 GMT	1	16	Simples	Escovado	2:30:00.763	Add
2	Projeto 2	Acabamento	Tue, 27 Sep	Wed, 28 Sep	2	1	Medio	Polido	2:30:00.763	Add

Figura 40 - UI - Informação das etapas ativas

Etapas com o resultado real

Id	Nome	Etapa	Data de Registro	Data da etapa	Numero Simples	Numero Complexos	Tipo Limpeza	Tipo Acabamento	Tipo Previsao	Valor real
1	Projeto 1	Corte	Tue, 27 Sep 2022 19:56:33 GMT	Wed, 28 Sep 2022 00:00:00 GMT	5	10			2:20:56.134	141
2	Projeto 2	Corte	Tue, 27 Sep 2022 20:06:01 GMT	Wed, 28 Sep 2022 00:00:00 GMT	5	3			1:40:19.177	120
1	Projeto 1	Dobra	Tue, 27 Sep 2022 19:56:58 GMT	Wed, 28 Sep 2022 00:00:00 GMT	4	1			3:06:05.853	187
2	Projeto 2	Dobra	Tue, 27 Sep 2022 20:06:20 GMT	Wed, 28 Sep 2022 00:00:00 GMT	3	1			2:14:31.835	135
1	Projeto 1	Furo	Tue, 27 Sep 2022 19:57:33 GMT	Wed, 28 Sep 2022 00:00:00 GMT	4	8			2:47:50.909	108
2	Projeto 2	Furo	Tue, 27 Sep	Wed, 28 Sep	4	4			2:06:14.484	127

Figura 41 - UI - Informação das etapas finalizadas

4.6 Análise crítica aos resultados

Os resultados obtidos permitem a realização inicial da comparação com valores reais de modo serem validados e, se necessário, corrigidas as previsões realizadas. Com base na base de dados gerada, considera-se que foram obtidos bons resultados iniciais.

Para a segunda fase do projeto, que corresponde à gestão de projetos, apresentam-se os resultados obtidos na tabela 11. É possível verificar que o tempo de execução previsto pelo modelo treinado, quando confrontado com valores novos, está próximo da realidade. Com estes resultados pode assumir-se que tanto o treino como a geração de dados foram tarefas realizadas com sucesso.

De modo a garantir e atestar esta qualidade, foram realizados testes reais na empresa utilizada como caso de estudo, que se disponibilizou e aceitou implementar este *software*. A maior diferença entre a previsão e o resultado real foi de aproximadamente 50 minutos na etapa de furo.

Tabela 11 - Comparação de valores

Nome do projeto	Etapa	Hora prevista (minutos)	Resultado real (minutos)
Projeto 1	Corte	140,56	141
Projeto 1	Dobra	186,32	187
Projeto 1	Furo	167,51	108
Projeto 1	Solda	165,45	200
Projeto 1	Tratamento	203,34	230
Projeto 1	Acabamento	150,00	130

5. Conclusões e Trabalho Futuro

5.1 Conclusões

Com o desenvolvimento deste trabalho de investigação pretende-se validar a aplicação de um sistema genérico de suporte à decisão que auxilie os processos de previsão e de gestão de projetos nas empresas de pequena dimensão do setor.

Através do caso de estudo, o objetivo é realizar uma comparação entre a realidade atual com o sistema automático que faz previsões para prazos de execução ajustadas ao tipo de objetos produzidos, garantindo também que nenhuma etapa de produção seja negligenciada.

Pretende-se, desta forma, aumentar a produtividade, evitar roturas e interrupções no processo produtivo e garantir o cumprimento dos contratos estabelecidos com os clientes, aumentando o grau de competitividade da empresa.

5.1.1 Contribuições e Discussão de Resultados

Com o desenvolvimento do projeto foram estudadas e implementadas várias redes

neurais artificiais de boa qualidade para a realização de previsão de tempos de execução, como se conseguiu verificar no tópico: Algoritmo de *Machine Learning*. Esta previsão é posteriormente utilizada para realizar, de forma semi-automática, a gestão de projetos (tópico: Gestão de projetos).

Dado o exemplo específico de um caso de estudo de uma empresa da área de metalomecânica, procedeu-se a um estudo de modo a verificar e validar as variáveis extraídas e utilizadas para realizar a previsão e consequente divisão do projeto em sub-etapas.

Após terminar a implementação do sistema e verificação tanto de métricas de performance das redes neurais treinadas e comparação com a realidade (de acordo com os últimos projetos iniciados pela empresa), pode assumir-se que os resultados obtidos são de boa qualidade. Embora ainda com capacidade para melhorias, o resultado é satisfatório devido à necessidade de fabricar dados (com base num conjunto de critérios pré-estabelecidos).

Por outro lado, a possibilidade de uma gestão visual de projetos é também considerada uma mais-valia pela empresa, estando o sistema a ser introduzido e a ter uma boa receção por parte da mesma. A sua utilização permite uma maior otimização do tempo do gestor, diminuindo o tempo despendido na determinação do tempo necessário para execução de cada etapa.

5.1.2 Trabalho realizado (conferências)

O desenvolvimento do sistema descrito permitiu a publicação de um artigo numa conferência:

Ribeiro, J., & Ramos, J. (2022). Forecasting system and project monitoring in industry. Distributed Computing and Artificial Intelligence, 19th International Conference [in press]

5.2 Trabalho Futuro

Como trabalho futuro, pretende-se deixar de usar os dados sintéticos que foram criados inicialmente para treinar as RNA's e preencher a base de dados com dados reais. A recolha destes dados, já iniciada, é um processo moroso, uma vez que para se realizar um treino mais adequado é necessária uma grande quantidade de dados. A criação de uma base de dados representativa da realidade irá permitir a realização de uma previsão mais precisa e realista.

Outro fator importante é validar os atributos extraídos e verificar se novos atributos devem ser utilizados, sendo que um dos atributos já está eleito a ser adicionado ao algoritmo que é o resultado real, ou seja, o número de minutos reais que uma determinada etapa demorou na realidade, trazendo benefícios para o treino do modelo.

Para aperfeiçoar o treino das RNA's, poderão também ser estudadas mais estruturas da rede neuronal, como por exemplo, percentagem teste/treino, número de camadas ocultas, número máximo de épocas, taxa de aprendizagem. Também será importante testar mais e avaliar outros modelos de aprendizagem.

Do ponto de vista do utilizador final é importante aperfeiçoar a interface de utilizador de modo que fique mais atrativo visualmente para o gestor.

Dado que o projeto foi desenvolvido de modo a ser implementado numa empresa de metalomecânica, pretende-se atualizar o modelo de dados de modo a permitir uma maior generalização e aplicabilidade noutro tipo de empresas com outro tipo de atividades comerciais.

Referencias bibliográficas

- [1] Diferentes abordagens para o aprendizado da rede neural artificial multilayer perceptron. Master's thesis, Curitiba
- [2] das Chagas, L.L., Samed, M.M.A.: Gestão de projetos aplicada ao desenvolvimento de produtos em uma indústria metal mecânica. Master's thesis, Trabalhos de Conclusão de Curso do DEP (2006)
- [3] Chawla, V., Chanda, A., Angra, S., Chawla, G.: The sustainable project management: A review and future possibilities. *Journal of Project Management* pp. 157–170 (2018). <https://doi.org/10.5267/j.jpms.2018.2.001>
- [4] Couto, E.: Conceção e desenvolvimento de um sistema de apoio à decisão para gestão de inventários no retalho. Master's thesis, Faculdade de Engenharia do Porto, Universidade do Porto, Porto (2019), <https://repositorio-aberto.up.pt/bitstream/10216/119569/2/329124.pdf>
- [5] CRUZ, F.: Scrum e pmbok unidos no gerenciamento de projetos 4, 416 (2013)

- [6] Da Silva Laureano, R.M., Cardoso Vieira Machado, M.J., Da Silva Laureano, L.M.: Maturity in management accounting: Exploratory study in Portuguese SME. *Society and Economy* 38(2), 139–156 (Jun 2016). <https://doi.org/10.1556/204.2016.38.2.1>
- [7] Esteves, N.: Previsão de Vendas, Distribuição e Reabastecimento Integrados para Retalho. Master's thesis, Faculdade de Engenharia da Universidade do Porto, Porto (2011), <https://repositorio-aberto.up.pt/bitstream/10216/61198/1/000148330.pdf>
- [8] Ferreira, A., Ferreira, R.P., da Silva, A.M., Ferreira, A., Sassi, R.J.: Um estudo sobre previsão da demanda de encomendas utilizando uma rede neural artificial pp. 353–364 (8 2016). <https://doi.org/10.5151/MARINE-SPOLM2015-140481>
- [9] Hallowell, R.: The relationships of customer satisfaction, customer loyalty, and profitability: an empirical study. *International Journal of Service Industry Management* 7(4), 27–42 (Oct 1996). <https://doi.org/10.1108/09564239610129931>
- [10] Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., Inman, D.J.: 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing* 151, 107398 (Apr 2021). <https://doi.org/10.1016/j.ymssp.2020.107398>
- [11] Kumar, I., Rawat, J., Mohd, N., Husain, S.: Opportunities of Artificial Intelligence and Machine Learning in the Food Industry. *Journal of Food Quality* 2021, 1–10 (Jul 2021). <https://doi.org/10.1155/2021/4535567>
- [12] Maulud, D., Abdulazeez, A.M.: A Review on Linear Regression Comprehensive in Machine Learning. *Journal of Applied Science and Technology Trends* 1(4), 140–147 (Dec 2020). <https://doi.org/10.38094/jastt1457>
- [13] Rezaei, M., Rezaei, H., Alipour, H., Salehi, S.: Service quality, client satisfaction, and personality. *Australian Journal of Basic and Applied Sciences* p. 10 (2011)
- [14] Rodrigues, B., Andrade, A.: O potencial da inteligência artificial para o desenvolvimento e competitividade das empresas: uma scoping review. *Gestão e Desenvolvimento* 29, 381–422 (5 2021). <https://doi.org/10.34632/GESTAOEDESENVOLVIMENTO.2021.10038>
- [15] Shamsuzzoha, A., Kankaanpaa, T., Nguyen, H., Nguyen, H.: Application of machine learning algorithm in the sheet metal industry: an exploratory case study. *International*

- Journal of Computer Integrated Manufacturing 35(2), 145–164 (Feb 2022).
<https://doi.org/10.1080/0951192X.2021.1972469>
- [16] Sousa, P., Tereso, A., Alves, A., Gomes, L.: Implementation of project management and lean production practices in a SME Portuguese innovation company. *Procedia Computer Science* 138, 867–874 (2018). <https://doi.org/10.1016/j.procs.2018.10.113>
- [17] Taulli, T.: *Artificial intelligence basics: a non-technical introduction*. Apress, New York (2019). <https://doi.org/10.1007/978-1-4842-5028-0>
- [18] Vichova, K., Taraba, P., Belantova, T.: Risk Management of the Project and the Use of Software in SME. *WSEAS TRANSACTIONS ON BUSINESS AND ECONOMICS* 17, 551–559 (May 2020). <https://doi.org/10.37394/23207.2020.17.54>
- [19] Zhang, X.D.: Machine learning. In: *A Matrix Algebra Approach to Artificial Intelligence*. Springer Singapore, Singapore (2020). <https://doi.org/10.1007/978-981-15-2770-9>
- [20] Wang, S.-C. (2003). Artificial Neural Network. *Interdisciplinary Computing in Java Programming*, 81–100. https://doi.org/10.1007/978-1-4615-0377-4_5
- [21] Kyriacou, C. (2007). Action Research: a Methodology for Change and Development - by Bridget Somekh. *British Journal of Educational Studies*, 55(4), 468–469. https://doi.org/10.1111/j.1467-8527.2007.00388_3.x
- [22] Ketkar, N., & Moolayil, J. (2021). *Deep learning with Python: learn best practices of deep learning models with PyTorch*. Apress.
- [23] wahyu prayogo. (2017). *TensorFlow A GUIDE TO BUILDING DEEP LEARNING SYSTEMS*. O'Reilly Media, Inc.
- [24] Ferreira, L., de Moura, G. L., Borenstein, D., & Fischmann, A. A. (2012). THE USE OF ARTIFICIAL NEURAL NETWORKS AS A STRATEGY FOR FORECASTING PRICES IN THE CONTEXT OF AGRIBUSINESS. *Review of Administration and Innovation - RAI*, 8(4). <https://doi.org/10.5773/RAI.V8I4.475>
- [25] A. R. C. Medeiros, Y. B. de Araújo, R. P. de T. Vianna, and R. M. de Moraes, “Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo,” *Saúde em Debate*, vol. 38, no. 100, pp. 104–118, 2014, doi: 10.5935/0103-104.20140016.

- [26] "(PDF) Predictive Neural Network Applications for Insurance Processes." https://www.researchgate.net/publication/335609766_Predictive_Neural_Network_Applications_for_Insurance_Processes.
- [27] I. Reis Costa, L. Faria, C. Pinto, and P. Orientadora, "A EVOLUÇÃO DOS DISPOSITIVOS DE ARMAZENAMENTO DE DADOS NA PERSPECTIVA DA HISTÓRIA".
- [28] V. Pattabiraman and H. Singh, "Deep Learning based Brain Tumour Segmentation," *WSEAS TRANSACTIONS ON COMPUTERS*, vol. 19, pp. 234–241, Jan. 2021, doi: 10.37394/23205.2020.19.29.
- [29] J. Lam, S. Abdul-AI, and A. R. Allouche, "Combining Quantum Mechanics and Machine-Learning Calculations for Anharmonic Corrections to Vibrational Frequencies," *J Chem Theory Comput*, vol. 16, no. 3, pp. 1681–1689, Mar. 2020, doi: 10.1021/ACS.JCTC.9B00964.
- [30] "The basic activation functions of the neural networks(Neural Networks... | Download Scientific Diagram." https://www.researchgate.net/figure/fig3-The-basic-activation-functions-of-the-neural-networksNeural-Networks_fig3_350567223.
- [31] "Máquina de vetores de suporte – Wikipédia, a enciclopédia livre." https://pt.wikipedia.org/wiki/M%C3%A1quina_de_vetores_de_suporte.
- [32] "Redes Bayesianas: uma breve (e leve) introdução." <https://pt.linkedin.com/pulse/rede-bayesianas-uma-breve-e-leve-introducao-ricardo-fischer>.
- [33] "Aprendizado por Reforço #1— Introdução | by Enzo Cardeal Neves | Turing Talks | Medium." <https://medium.com/turing-talks/aprendizado-por-reforco-1-introducao-7382ebb641ab>.
- [34] "Algoritmo Genético para o Problema da Mochila | by Vitor Emanuel Batista | Medium." <https://vitorebatista.medium.com/algoritmo-genetico-para-o-problema-da-mochila-5910f90f9488>.
- [35] "Crossover Genetic algorithm Genetics Genetic operator, science, purple, angle, text png | PNGWing." <https://www.pngwing.com/en/free-png-hlkos>.

- [36] R. Kato, V. Paiva, and S. Izidoro, "Algoritmos Genéticos," *BIOINFO - Revista Brasileira de Bioinformática e Biologia Computacional*, Jul. 2021, doi: 10.51780/978-6-599-275326-13.
- [37] "Elitism genetic algorithm functioning scheme | Download Scientific Diagram." https://www.researchgate.net/figure/Elitism-genetic-algorithm-functioning-scheme_fig1_235683206.
- [38] "Metaheurísticas." https://moodle2.estg.ipp.pt/moodle2021/pluginfile.php/75131/mod_resource/content/2/1-Metaheurísticas.pdf
- [39] "Introduction to Evolutionary Algorithms | by Devin Soni | Towards Data Science." <https://towardsdatascience.com/introduction-to-evolutionary-algorithms-a8594b484ac>.
- [40] "Métricas de Erros Estatísticos no MS Excel | Fabio Baldini." <https://fabiobaldini.com.br/metricas-de-erros-estatisticos-no-ms-excel/>.
- [41] "RMSE ou MAE? Como avaliar meu modelo de machine learning?" https://www.linkedin.com/pulse/rmse-ou-mae-como-avaliar-meu-modelo-de-machine-learning-rezende?trk=public_profile_article_view.
- [42] "Demystifying 'Confusion Matrix' Confusion | by SalRite | Towards Data Science." <https://towardsdatascience.com/demystifying-confusion-matrix-confusion-9e82201592fd>.
- [43] "Angular." <https://angular.io/>.
- [44] "Welcome to Python.org." <https://www.python.org/>.
- [45] "MongoDB Atlas: Cloud Document Database | MongoDB." https://www.mongodb.com/cloud/atlas/lp/try4?utm_source=google&utm_campaign=search_gs_pl_evergreen_atlas_core_prosp-brand_gic-null_emea-pt_ps-all_desktop_eng_lead&utm_term=mongodb&utm_medium=cpc_paid_search&utm_ad=e&utm_ad_campaign_id=12212624551&adgroup=115749716383&gclid=Cj0KCQjw166aBhDEARIsAMEyZh46FSYWQSLCWdqUBQ2eJndellblzpZ_FvJpXpPbbxaBEFA7IQmbnJcaAnt-EALw_wcB.
- [46] "API Documentation & Design Tools for Teams | Swagger." <https://swagger.io/>.

- [47] “PyCharm: the Python IDE for Professional Developers by JetBrains.”
<https://www.jetbrains.com/pycharm/>.
- [48] “Visual Studio Code - Code Editing. Redefined.” <https://code.visualstudio.com/>.
- [49] “scikit-learn: machine learning in Python — scikit-learn 1.1.2 documentation.”
<https://scikit-learn.org/stable/index.html>.
- [50] “Welcome to Flask — Flask Documentation (2.2.x).”
<https://flask.palletsprojects.com/en/2.2.x/>.
- [51] J. Antonio et al., “Inteligencia artificial, sistemas inteligentes, agentes inteligentes,”
RECIMUNDO: Revista Científica de la Investigación y el Conocimiento, ISSN-e 2588-073X, Vol. 4, No. 2, 2020, págs. 16-30, vol. 4, no. 2, pp. 16–30, 2020, doi:
10.26820/recimundo/4.(2).mayo.2020.16-30.
- [52] M. I. Castiieira, D. Maria, and C. Monard, “APRENDIZADO DE MÁQUINA POR
EXEMPLOS USANDO ÁRVORES DE DECISÃO,” Nov. 2019, doi:
10.11606/D.55.2019.TDE-21022019-100634.
- [53] D. N. Muller and F. Andrade, “Introdução às Redes Neurais Artificiais Cite this paper”.
- [54] A. C. Lorena and A. C. P. L. F. de Carvalho, “Uma Introdução às Support Vector
Machines,” Revista de Informática Teórica e Aplicada, vol. 14, no. 2, pp. 43–67, Dec.
2007, doi: 10.22456/2175-2745.5690.
- [55] R. Ligeiro Marques and I. Dutra, “Redes Bayesianas: o que são, para que servem,
algoritmos e exemplos de aplicações”.
- [56] A. do Eati Frederico Westphalen and -Rs Ano, “Aprendizagem por Reforço Clássica
e Conexionista: análise de aplicações,” pp. 299–302, 2015.
- [57] G. Silva, D. Marildá, F. Aprendendo, and F. Marme, “CAPÍTULO 3 INTRODUÇÃO
AOS ALGORITMOS GENÉTICOS Related papers”.

Apêndice

No desenvolvimento do sistema foram criadas várias páginas web com formulários nos quais o gestor pode extrair, inserir ou editar a informação apresentada. As imagens apresentadas desde a Figura 42 à **Erro! A origem da referência não foi encontrada.** representam diversos exemplos desses formulários ou do gráfico apresentado ao gestor com a alocação de etapas.

Add

Nome	Número Funcionarios Corte	Número Maquinas Corte	Número Funcionarios Dobra
<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
Número Maquinas Dobra	Número Funcionarios Furo	Número Maquinas Furo	Número Funcionarios Solda
<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
Número Maquinas Solda	Número Funcionarios Tratamento	Número Maquinas Tratamento	Número Funcionarios Acabamento
<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
Número Maquinas Acabamento			
<input type="text"/>			
<input type="button" value="Save"/>	<input type="button" value="Cancel"/>		

Figura 42 - UI - Adicionar empresa

Edit

Nome	Número Funcionarios Corte	Número Maquinas Corte	Número Funcionarios Dobra
<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
Número Maquinas Dobra	Número Funcionarios Furo	Número Maquinas Furo	Número Funcionarios Solda
<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
Número Maquinas Solda	Número Funcionarios Tratamento	Número Maquinas Tratamento	Número Funcionarios Acabamento
<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
Número Maquinas Acabamento			
<input type="text"/>			
<input type="button" value="Save"/>	<input type="button" value="Cancel"/>		

Figura 43 - UI - Alteração da empresa

Previsão Corte

Name:

Número Simples:

Número Complexos:

Figura 44 - UI – Formulário de previsão da etapa de corte

Previsão Dobra

Name:

Número Simples:

Número Complexos:

Figura 45 - UI - Formulário de previsão da etapa de dobra

Previsão Solda

Name:

Número Simples:

Número Complexos:

Figura 46 - UI - Formulário de previsão da etapa de solda

Previsão Furo

Name:

Número Simples:

Número Complexos:

Figura 47 - UI - Formulário de previsão da etapa de furo

Previsão Tratamento

Name:

Número Simples:

Número Complexos:

Figura 48 - UI - Formulário de previsão da etapa de tratamento

Adicionar a gestão de projetos

Lista de etapas

-
-
-
-
-
-

Figura 49 - Lista de etapas previstas

Adicionar a gestão de projetos

Id	Nome	Etapa	Data de Registo	Numero Simples	Numero Complexos	Previsao	
1	Projeto 1	Furo	Tue, 27 Sep 2022 19:57:33 GMT	4	8	2:47:50.909	Adicionar

Figura 50 - UI - Previsão da etapa furo

Adicionar a gestão de projetos

Id	Nome	Etapa	Data de Registo	Numero Simples	Numero Complexos	Previsao	
1	Projeto 1	Dobra	Tue, 27 Sep 2022 19:56:58 GMT	4	1	3:06:05.853	Adicionar

Figura 51 - UI - Previsão da etapa dobra

Adicionar a gestão de projetos

Id	Nome	Etapa	Data de Registo	Numero Simples	Numero Complexos	Previsao	
1	Projeto 1	Solda	Tue, 27 Sep 2022 19:58:02 GMT	2	6	2:45:52.435	Adicionar

Figura 52 - UI - Previsão da etapa solda

Adicionar a gestão de projetos

Id	Nome	Etapa	Data de Registo	Numero Simples	Numero Complexos	Previsao	
1	Projeto 1	Tratamento	Tue, 27 Sep 2022 19:58:37 GMT	1	16	3:23:34.374	Adicionar

Figura 53 - UI - Previsão da etapa tratamento

Adicionar a gestão de projetos

Id	Nome	Etapa	Data de Registo	Numero Simples	Numero Complexos	Previsao	
1	Projeto 1	Acabamento	Tue, 27 Sep 2022 19:59:32 GMT	1	16	Escovado Simples 2:30:00.763	Adicionar

Figura 54 - UI - Previsão da etapa acabamentoo

Valor Real (Minutos)

Figura 55 - UI - Inserir valor real