

Dimensionamento de ligações metálicas suportado por técnicas de Machine Learning

CARLOS VASCONCELOS TEIXEIRA DE MAGALHÃES

Dissertação submetida para satisfação parcial dos requisitos do grau de
MESTRE EM ENGENHARIA CIVIL — ESPECIALIZAÇÃO EM ESTRUTURAS E GEOTECNIA

Orientador: Professor Doutor José Miguel de Freitas Castro

JUNHO DE 2023

MESTRADO EM ENGENHARIA CIVIL 2022/2023

DEPARTAMENTO DE ENGENHARIA CIVIL

Tel. +351-22-508 1901

✉ m.ec@fe.up.pt

Editado por

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO

Rua Dr. Roberto Frias

4200-465 PORTO

Portugal

Tel. +351-22-508 1400

✉ feup@fe.up.pt

🌐 <http://www.fe.up.pt>

Reproduções parciais deste documento serão autorizadas na condição que seja mencionado o Autor e feita referência a *Mestrado em Engenharia Civil — 2022/2023 — Departamento de Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal, 2023*.

As opiniões e informações incluídas neste documento representam unicamente o ponto de vista do respetivo Autor, não podendo o Editor aceitar qualquer responsabilidade legal ou outra em relação a erros, ou omissões que possam existir.

Este documento foi produzido a partir de versão eletrónica fornecida pelo respetivo Autor.

Aos meus Pais,

"It always seems impossible until it's done."

Nelson Mandela

AGRADECIMENTOS

Um agradecimento muito especial ao meu orientador e professor José Miguel Castro por todo o tempo despendido comigo para me proporcionar o melhor acompanhamento possível, sempre com muita vontade e propondo-me tarefas desafiantes.

Um agradecimento muito especial à empresa que me acolheu, Bysteel, que foi crucial em todo este processo e que desde o primeiro dia me fizeram sentir em casa, estando sempre disponíveis a ajudar-me em qualquer situação. Um agradecimento ao João Gil Dias, ao Nuno Neves e à Regina Sousa, e em especial João Manuel Sousa que me orientou na empresa e reuniu comigo sempre que necessitava.

Um agradecimento muito especial aos meus pais por todo o apoio que me deram ao longo do desenvolvimento desta dissertação, mas também ao longo de todo o curso, sem eles seria incapaz de ter tido este percurso tão desafiante.

Um agradecimento muito especial ao José Neto, uma pessoa que conheci ao longo da realização desta dissertação e que esteve sempre disponível a ajudar-me sem ter a necessidade de o fazer. Aprendi muito na formação fornecida à OERN e ao longo de todas as reuniões que fomos agendando para debater certos problemas ou questões relacionadas com o “Machine Learning”.

Por fim, um agradecimento a todos os que fizeram parte do meu percurso ao longo destes 5 anos na Faculdade de Engenharia da Universidade do Porto, desde professores a alunos, que foi toda essa passagem que me tornou uma melhor pessoa e um melhor profissional.

RESUMO

Cada vez mais a utilização de programação e inteligência artificial no trabalho são ferramentas essenciais para uma maior produtividade e consequentemente competitividade no mercado, e com isso o mercado de trabalho de engenharia civil também sofrerá mudanças num futuro muito próximo com o aparecimento de técnicas como o “Machine Learning” entre outras.

Um processo de dimensionamento de ligações metálicas é um dos casos que a ajuda desta nova revolução tecnológica pode entrar em campo, uniformizando soluções, aumentando a sua rapidez e diminuindo a probabilidade de erros, sendo portando uma ferramenta que será imprescindível para todos os engenheiros civis.

Esta dissertação apresenta a realização de um código inserido numa “interface” gráfica para a verificação de ligações metálicas e aplicação de um processo de “Machine Learning” que a partir de uma base de dados consegue dimensionar uma ligação metálica do tipo *Fin-Plate* com uma grande probabilidade de esta passar em todas as verificações de segurança necessárias ou pedidas por diferentes documentações existentes, apenas com base em informações de ligações anteriormente dimensionadas.

O objetivo é atingindo criando um modelo de “Machine Learning” capaz de atribuir 8 características necessárias para o dimensionamento em que estas são validadas pelo programa de verificações de segurança desenvolvido.

PALAVRAS-CHAVE: DIMENSIONAMENTO DE LIGAÇÕES METÁLICAS, EUROCÓDIGO 3, MACHINE LEARNING, LIGAÇÃO FIN-PLATE, INTELIGÊNCIA ARTIFICIAL

ABSTRACT (ARIAL 11PT BOLD)

Increasingly the use of programming and artificial intelligence at work are essential tools for greater productivity and consequently competitiveness in the market, and with this the civil engineering job market will also undergo changes in the very near future with the appearance of techniques such as Machine Learning among others.

A process of sizing metal connections is one of the cases that the help of this new technological revolution can enter the field, standardizing solutions, increasing their speed, and decreasing the likelihood of errors, being a tool that will be essential for all civil engineers.

This dissertation presents the realization of a code inserted in a graphical “interface” for the verification of metallic connections and application of a Machine Learning process that from a database can size a metallic connection of the Fin-Plate type with a high probability of passing all the necessary safety checks or requested by different existing documentation.

The goal is to achieve by creating a Machine Learning model capable of assigning eight characteristics necessary for scaling in which these are validated by the security verification program developed.

KEYWORDS: SIZING OF METAL BONDS, SAFETY VERIFICATION, MACHINE LEARNING, FIN-PLATE BONDING, ARTIFICIAL INTELLIGENCE.

ÍNDICE GERAL

AGRADECIMENTOS	i
RESUMO	iii
ABSTRACT	v
1 INTRODUÇÃO	1
1.1. CONSIDERAÇÕES INICIAIS	1
1.2. OBJETIVOS	1
1.3. ESTRUTURA	2
2 DIMENSIONAMENTO DE LIGAÇÕES METÁLICAS SEGUNDO O EUROCÓDIGO 3	3
2.1 CLASSIFICAÇÃO DE LIGAÇÕES	3
2.2 FIN PLATE	5
2.3 CÁLCULO DA LIGAÇÃO	6
2.3.1 Disposições dos parafusos	6
2.3.3 Capacidade de rotação	7
2.3.3 Ductilidade da ligação	9
2.3.2 Resistência ao corte dos parafusos	10
2.3.3 Resistência ao esmagamento	12
2.3.4 Resistência ao corte	14
2.3.7 Resistência à tração	16
2.3.7 Resistência à compressão	17
2.3.5 Resistência à flexão da chapa	18
2.3.6 Resistência à encurvadura devido à flexão	20
2.3.8 Resistência à flexão do entalhe	21

2.3.8	Resistência da soldadura para um cordão de angulo.....	23
2.3.9.	Análise local da resistência à flexão da viga na zona dos parafusos.....	24
2.3.10.	Estabilidade local de vigas com entalhe.....	26
2.3.10.	Resistência ao corte da viga de suporte.....	27
3	MACHINE LEARNING NO CONTEXTO DO PROJETO DE ESTRUTURAS.....	29
3.1.	MACHINE LEARNING	29
3.2.	MODELOS DE MACHINE LEARNING	30
3.2.1.	k-nearest Neighbors.....	31
3.2.2.	Linear Regression.....	32
3.2.3.	Decision Tree.....	33
3.2.4.	Random Forest	34
3.3.	MÉTRICAS DE AVALIAÇÃO.....	35
3.3.1.	Métricas para modelos de classificação	36
3.3.2.	Métricas para modelos de regressão	38
4	DESENVOLVIMENTO DE UM MODELO DE MACHINE LEARNING.....	41
4.1.	CRIAÇÃO DA BASE DE DADOS	41
4.2.	ANÁLISE DA BASE DE DADOS	42
4.2.1.	Altura da viga suportada (h_{b1})	45
4.2.2.	Espessura da alma da viga suportada (t_{w1})	47
4.2.3.	Esforço de corte ($V_{z,Ed}$).....	48
4.3.	ANÁLISE E MODELAÇÃO INDIVIDUAL DAS VARIÁVEIS	49
4.3.1.	Área total transversal dos parafusos ($n \times A$)	50

4.3.2.	Combinação do número de parafusos com o diâmetro dos mesmos ($n \times d$)	53
4.3.3.	Número de parafusos (n)	56
4.3.4.	Diâmetro (d)	59
4.3.5.	Altura da chapa (h_p)	59
4.3.6.	Área transversal da chapa ($h_p \times t_p$)	62
4.3.7.	Espessura da chapa (t_p)	65
4.3.8.	Número de linhas de parafusos (n_1)	65
4.3.9.	Número de colunas (n_2)	68
4.3.10.	Distância ao bordo livre do perfil suportado na direção do esforço (e_{1b})	68
4.3.11.	Distância ao bordo livre da chapa na direção do esforço (e_1)	71
4.3.12.	Afastamento dos parafusos na direção do esforço (p_1)	72
4.3.13.	Correções aos valores obtidos	72
4.3.14.	Distância ao bordo livre da chapa na direção perpendicular ao esforço (e_2) ..	72
4.3.15.	Distância ao bordo livre da chapa na direção perpendicular ao esforço (e_{2b}) .	75
4.3.16.	Afastamento dos parafusos na direção perpendicular ao esforço (p_2)	76
4.3.17.	Espessura do cordão de soldadura (a)	76
4.5.	CONCLUSÃO	77
5	DESENVOLVIMENTO DE UMA FERRAMENTA PARA O CÁLCULO DE LIGAÇÕES	79
5.1.	CRIAÇÃO DO CÓDIGO (BACK END)	79
5.1.1.	Criação do código de verificações	79
5.1.2.	Estrutura de dados	80
5.2.	CRIAÇÃO DE UMA “INTERFACE” (FRONT END)	81
5.3.	INCORPORAÇÃO DO MODELO DE MACHINE LEARNING	88

5.4. VALIDAÇÃO DA APLICAÇÃO	90
6 CONSIDERAÇÕES FINAIS.....	93
6.1. CONCLUSÕES	93
6.1. DESENVOLVIMENTOS FUTUROS	94
REFERÊNCIAS BIBLIOGRÁFICAS	95

ÍNDICE DE FIGURAS

Fig. 1 - Desenhos tipo de ligações metálicas	3
Fig. 2 - Relação momento/rotação	4
Fig. 3 - Tipos de ligações Fin Plate	5
Fig. 4 - Disposição de furos e representação das distâncias	6
Fig. 5 - Ângulo de rotação disponível consoante o momento aplicado	8
Fig. 6 - Ângulo de rotação necessário	9
Fig. 7 - Resistência de corte de um parafuso	10
Fig. 8 - Influência dos planos de corte	11
Fig. 9 - Esquema de Inércia Polar dos parafusos	11
Fig. 10 - Esmagamento originado por um parafuso	13
Fig. 11 - Rotura em bloco	14
Fig. 12 - Rotura por tração	16
Fig. 13 - Rotura por compressão	17
Fig. 14 - Flexão originada por excentricidade de corte	18
Fig. 15 - Torção lateral	20
Fig. 16 - Flexão da viga na zona do entalhe	22
Fig. 17 – Cordão de ângulo	23
Fig. 18 - Análise local da zona dos parafusos à flexão	25
Fig. 19 - Estabilidade local de vigas com entalhes	26
Fig. 20 - Corte na viga de suporte	27
Fig. 21 - Etapas para solucionar um problema por “Machine Learning”	29
Fig. 22 - k-nearest Neighbors	31

Fig. 23 - Linear Regression	32
Fig. 24 - Mesma regressão para conjunto de dados diferentes	33
Fig. 25 - Decision Tree	34
Fig. 26 - Árvore de decisão	34
Fig. 27 - Random Forest	35
Fig. 28 - Divisão em k-folds	36
Fig. 29 – Exemplo de resultados atribuídos às classes	37
Fig. 30 - Matriz correlação de variáveis	43
Fig. 31 - Dispersão da base de dados	44
Fig. 32 - Boxplot altura da viga suportada (h_b)	45
Fig. 33 - Dispersão da altura da viga suportada (h_b)	46
Fig. 34 - Boxplot da espessura da alma da viga suportada (t_w)	47
Fig. 35 - Dispersão da espessura da alma da viga suportada (t_w)	48
Fig. 36 - Boxplot esforço de corte ($V_{z,Ed}$)	49
Fig. 37 - Dispersão esforço de corte (V_z)	49
Fig. 38 - Descoberta sequencial de variáveis	50
Fig. 39 - Dispersão área dos parafusos ($n \times A$)	51
Fig. 40 - Variação das variáveis V_z e $n \times A$ normalizadas	51
Fig. 41 - Diferença das variáveis normalizadas	52
Fig. 42 - Relação $V_z - n \times A$	52
Fig. 43 - Dispersão $n \times d$	53
Fig. 44 - Variação das variáveis V_z , $n \times A$ e $n \times d$ normalizadas	54
Fig. 45 - Diferenças das variáveis normalizadas	54
Fig. 46 - Relação $n \times A - n \times d$	55

Fig. 47 - Relação $V_z - n \times d$	55
Fig. 48 - Dispersão do número de parafusos (n)	56
Fig. 49 - Variação das variáveis normalizadas V_z , $n \times d$ e n (Parafusos)	57
Fig. 50 - Diferença das variáveis normalizadas	57
Fig. 51 - Relação $n \times d - n$ parafusos	58
Fig. 52 . Relação $V_z - n$ parafusos	58
Fig. 53 - Dispersão da altura da chapa	59
Fig. 54 - Variação das variáveis normalizadas V_z , h_b e h_p	60
Fig. 55 - Diferença das variáveis normalizadas	60
Fig. 56 - Relação $h_b - h_p$	61
Fig. 57 . Relação $V_z - h_p$	61
Fig. 58 - Dispersão da área transversal da chapa	62
Fig. 59 - Variação das variáveis normalizadas V_z , $n \times A$, h_p e $h_p \times t_p$	63
Fig. 60 - Diferença das variáveis normalizadas	63
Fig. 61 - Relação $h_p - h_p \times t_p$	64
Fig. 62 . Relação $V_z - h_p \times t_p$	64
Fig. 63 - Relação $n \times A - h_p \times t_p$	64
Fig. 64 - Dispersão do número de linhas de parafusos (n_1)	66
Fig. 65 - Variação das variáveis normalizadas n , n_1 e h_p	66
Fig. 66 - Relação $h_p - n_1$	67
Fig. 67 - Relação $n - n_1$	67
Fig. 68 - Dispersão da variável e_{1b}	69
Fig. 69 - Variação das variáveis normalizadas h_b-h_p e e_{1b}	69
Fig. 70 - Diferença das variáveis normalizadas	70

Fig. 71 – Relação h_b - h_p - e_{1b}	70
Fig. 72 - Esquema do cálculo da variável e_1	71
Fig. 73 - Dispersão da variável e_2	73
Fig. 74 - Variação das variáveis normalizadas e_1 , e_2 , d e h_b	73
Fig. 75 - Relação d - e_2	74
Fig. 76 - Relação e_1 - e_2	74
Fig. 77 - Relação h_b - e_2	74
Fig. 78 - Dispersão da diferença das variáveis e_2 - e_{2b}	75
Fig. 79 – Dispersão da variável p_2	76
Fig. 80 - Variação das variáveis normalizadas a e t_{wmin}	77
Fig. 81 - Peça de código de uma verificação de segurança	80
Fig. 82 - Estrutura de dados JSON	81
Fig. 83 - Comando "Designer" para criação de janelas gráficas	82
Fig. 84 - Página 1 da interface	83
Fig. 85 - Página 2 da interface	83
Fig. 86 - Página 3 da interface	84
Fig. 87 - Página 4 da interface	84
Fig. 88 - Página 5 da interface	85
Fig. 89 - Página 6 da interface	85
Fig. 90 - Função "salvar valores"	86
Fig. 91 - Conversão da estrutura de dados JSON de entrada para um dicionário Python	86
Fig. 92 - Exemplo de uma verificação de segurança	87
Fig. 93 - Exemplo do "dicionário total" para uma verificação	87
Fig. 94 - Conversão do "dicionário total" em uma estrutura de dados JSON	87

Fig. 95 - Conversão da estrutura de dados JSON com os resultados em um dicionário	87
Fig. 96 - Incorporação do Machine Learning	88
Fig. 97 - Função guardar parâmetros necessário para Machine Learning	89
Fig. 98 - Abertura dos ficheiros com os modelos de Machine Learning gravados	89
Fig. 99 - Conversão dos parâmetros de entrada para um dicionário	89
Fig. 100 - Uma das funções para a estimativa de uma variável	90
Fig. 101 - Dicionário "obj_final" convertido para uma estrutura de dados JSON	90

SÍMBOLOS, ACRÓNIMOS E ABREVIATURAS

d – Diâmetro nominal do parafuso

EC3 – Eurocódigo 3

d0 — diâmetro do furo para um parafuso

e1 — distância, para qualquer das peças de ligação, entre o centro do furo de um parafuso e a extremidade adjacente, medida na direção da transmissão do esforço

e2 — distância, para qualquer das peças de ligação, entre o centro do furo de um parafuso e a extremidade adjacente, medida na direção perpendicular à transmissão do esforço

p1 — distância entre os eixos dos parafusos de uma fiada, medida na direção da transmissão dos esforços

ML – Machine Learning

p2 — distância, medida perpendicularmente à direção da transmissão do esforço, entre fiadas adjacentes de parafusos

tw — espessura da alma

tp — espessura da chapa

Fv,Rd – valor de cálculo da resistência ao esforço transversal por parafuso

z – Braço do binário

N – Esforço axial

V – Esforço transversal

M – Momento fletor

K — Coeficiente de transmissão térmica [W/m²K]

E - Módulo de elasticidade [GPa]

KNN – KNNNeighbors

DEC - Departamento de Engenharia Civil

FEUP — Faculdade de Engenharia da Universidade do Porto

Ref - Referência

Dept - Departamento

Tab – Tabela

Fig - Figura

ÍNDICE DE TABELAS

Tabela 1 - Tabela resumo do Quadro 3.3	7
Tabela 2 - Caracterização de fatores de correlação	43
Tabela 3 - Comparação de modelos para $n \times A$	53
Tabela 4 - Comparação de modelos para $n \times d$	55
Tabela 5 - Comparação de modelos para n parafusos	58
Tabela 6 - Comparação de modelos para altura da chapa	61
Tabela 7 - Comparação de modelos de regressão para $h_p \times t_p$	65
Tabela 8 - Comparação de modelos de classificação $n1$	67
Tabela 9 - Comparação de modelos para e_{1b}	71
Tabela 10 - Comparação de modelos para e_2	75
Tabela 11 - Comparação de resultados das características de ligações	91

1

INTRODUÇÃO

1.1. CONSIDERAÇÕES INICIAIS

A competitividade em todas as indústrias tem aumentado significativamente, e o uso de tecnologias tornou-se indispensável para as empresas poderem competir nos diferentes mercados. A atual revolução tecnológica está intimamente ligada ao uso da inteligência artificial e à maneira como ela pode ser aproveitada em cada setor e área.

Na área da engenharia civil, é comum notar uma relativa falta de evolução tecnológica e uma dificuldade em se uniformizar soluções, dependendo fortemente da subjetividade e opinião de cada profissional. Contudo, há um grande potencial para o uso de novas tecnologias, como a inteligência artificial, no processo de dimensionamento de ligações metálicas.

Esses recursos tecnológicos surgiram nos últimos anos e podem acelerar o processo de criação de ligações metálicas e diminuir a hipótese de erros. Isso torna a engenharia civil cada vez mais próxima de outras indústrias, beneficiando-se das vantagens proporcionadas pela automação e pelo uso de métodos mais consistentes e objetivos.

1.2. OBJETIVOS

O objetivo principal desta dissertação é enfatizar a relevância do uso de técnicas avançadas, como o “Machine Learning”, na área da engenharia civil. O trabalho trata do dimensionamento de uma ligação metálica do tipo viga-viga, começando com a descrição do método de cálculo tradicionalmente utilizado. A partir daí, é criada uma aplicação que permite realizar essa verificação de segurança de maneira mais rápida e precisa, reduzindo a possibilidade de erros humanos. Em seguida, é criada uma ferramenta de “Machine Learning” que acelera ainda mais o processo de dimensionamento da ligação, dimensionando todas as características ao seu permitindo definir todos os parâmetros necessários à sua caracterização, desde características geométricas até quantidades e resistências. Isso possibilita que a ligação seja praticamente dimensionada e verifique muitas das verificações de segurança sem a

necessidade de iterações demoradas e dispendiosas. O objetivo é também tornar as soluções atribuídas mais uniformes, garantindo maior eficiência e confiabilidade.

Em suma, as mesmas soluções atribuídas pelo processo de “Machine Learning” podem ser verificadas pela aplicação criada para digitalizar todo o processo de dimensionamento de uma ligação metálica usando toda a tecnologia necessária para auxiliar este processo.

1.3. ESTRUTURA

A presente dissertação está dividida em seis Capítulos, nos quais são apresentadas as evidências científicas atualizadas sobre os temas tratados.

No segundo Capítulo, é realizada uma revisão da literatura sobre o processo de dimensionamento e verificação de segurança de ligações metálicas. Esta revisão permite compreender os conceitos teóricos fundamentais do dimensionamento, que serão essenciais para a criação do modelo de “Machine Learning” e para a construção da ferramenta de cálculo. Alguns desses conceitos foram abordados na disciplina de Estruturas Metálicas e Mistas e aprofundados em contexto empresarial na empresa bysteel, com ênfase maior no tipo de ligação abordada no estudo.

No terceiro Capítulo, são introduzidos os princípios fundamentais para a aplicação de técnicas de “Machine Learning” em projetos de engenharia e em outros contextos. As métricas de avaliação dos modelos são aprofundadas para uma melhor decisão entre que modelos escolher.

No quarto Capítulo, são aplicados os modelos de “Machine Learning” estudados de forma a estimar os parâmetros necessários de uma ligação metálica do tipo Fin-Plate e chegar a uma solução final de ligação com apenas 3 parâmetros de entrada.

No quinto Capítulo, é apresentado o desenvolvimento de uma aplicação computacional destinada ao cálculo de ligações metálicas do tipo viga-viga de acordo com a Parte 1-8 do Eurocódigo 3 (Norma Portuguesa, 1993b). Esta aplicação foi criada em Python, uma linguagem atual, com uma interface que pode ser usada por utilizadores com diferentes níveis de conhecimento técnico na área. Ainda é realizada uma validação desta ferramenta comparando as características definidas por um projetista e as características estimadas pelos modelos de Machine Learning.

No sexto e último Capítulo, são apresentadas as conclusões obtidas a partir do uso dessa tecnologia, além de discutirem possíveis melhorias e futuras pesquisas nesse campo. A interface é validada para as verificações de segurança de ligações metálicas já dimensionadas, bem como para o dimensionamento de uma ligação apoiada num modelo de “Machine Learning”.

2

DIMENSIONAMENTO DE LIGAÇÕES METÁLICAS SEGUNDO O EUROCÓDIGO 3

2.1 CLASSIFICAÇÃO DE LIGAÇÕES

No contexto Europeu, o cálculo de ligações é feito com base na parte 1-8 do EC3 (NP EN 1993-1-8). Ainda assim para o processo de verificação e dimensionamento de ligações metálicas podem ser usadas como apoio várias interpretações do Eurocódigo 3, e ainda a parte 1-1 do EC3 (NP EN 1993-1-1). Estas documentações preocupam-se em dimensionar uma ligação em relação à sua capacidade resistente, mas também em relação à sua rotação, rigidez e ductilidade. Com isto, para se conseguir identificar modos de rotura e particularidades de cada ligação é importante classificar os tipos de ligações existentes (Kuang, 2018b):

a) Consoante os elementos a ligar:

- Viga – Viga;
- Coluna – Coluna;
- Viga – Coluna;
- Coluna – Base;




Fig. 1 - Desenhos tipo de ligações metálicas

b) Segundo o comportamento das ligações ou rigidez:

- Articulado – No qual se admite que a ligação não transmite momentos fletores, ocorrendo por isso rotações relativas entre os elementos ligados. Em termos de modelação, o seu comportamento é simulado com base na consideração de rótulas (Zona 1 – Figura 2);
- Contínuo – No qual se admite que a ligação consegue transmitir momentos, sendo a rotação relativa entre elementos ligados praticamente nula. (Zona 3 – Figura 2);
- Semicontínuo – No qual se admite que o comportamento tem de ser analisado, não se enquadrando em nenhum dos outros comportamentos acima, originando ligações semi-rígidas (Zona – Figura 2).




Fig. 2 - Relação momento/rotação

(Mahmood Md, 2016)

Para a categoria de ligações articuladas é preciso garantir que a ligação tem uma capacidade rotação suficiente de modo a não desenvolver momentos significativos, tal como uma ductilidade suficiente, permitindo uma redistribuição de esforços internos, evitando assim roturas frágeis. (Teixeira Araújo Peixoto, 2008). Apesar destas garantias, ao assumir uma ligação rotulada considera-se deslocamentos superiores aos deslocamentos reais devido à rigidez que não é considerada, o que permite a estar do lado da segurança.

c) Segundo a forma de ligação:

- Parafusos, rebites ou cavilhas;
- Soldaduras;

Para ligações aparafusadas solicitadas ao esforço de corte pode-se ainda dividir em 3 categorias:

- Categoria A: Ligação resistente ao esmagamento
Não é requerido qualquer pré-esforço nem disposições especiais. O valor de cálculo do esforço de corte no estado limite último não deverá exceder o valor de cálculo da resistência ao corte, nem o valor de cálculo da resistência ao esmagamento.
- Categoria B: Ligação resistente ao escorregamento no estado limite de utilização

Deverão utilizar-se parafusos pré-esforçados. Não deverá ocorrer escorregamento para o limite de utilização. O valor de cálculo da força de corte no estado limite de utilização não deverá ser superior ao valor de cálculo da resistência ao escorregamento. O valor de cálculo do esforço de corte no estado limite último não deverá exceder o valor de cálculo da resistência ao corte, nem o valor de cálculo da resistência ao esmagamento.

- **Categoria C: Ligação resistente ao escorregamento no estado limite último**

Deverão utilizar-se parafusos pré-esforçados. Não deverá ocorrer escorregamento para o limite último. O valor de cálculo da força de corte no estado limite último não deverá ser superior ao valor de cálculo da resistência ao escorregamento. O valor de cálculo do esforço de corte no estado limite último não deverá exceder o valor de cálculo da resistência ao corte, nem o valor de cálculo da resistência ao esmagamento. Além disso, no caso de uma ligação tracionada o valor de cálculo para o estado limite último da resistência plástica da secção útil que interceta os furos dos parafusos não pode ser excedido.

2.2 FIN PLATE

O foco desta dissertação será a ligação do tipo “Fin Plate”, a qual se insere nas ligações articuladas e que pode ser utilizada para ligações viga-viga ou para ligações viga-coluna (Kuang, 2018a). Esta ligação é composta por uma chapa aparafusada ao perfil suportado e soldada ao perfil de suporte.




Fig. 3 - Tipos de ligações Fin Plate

(mec Engineering Spreadsheets, 2023)

Como referido anteriormente, este tipo de ligações insere-se na classificação de ligações articuladas, não desenvolvendo momentos, podendo sofrer rotações (controladas). Assim este tipo de ligação serve principalmente para transmitir esforços de corte e também esforços axiais (tração e compressão).

Do ponto de vista de execução e produção, sabe-se que os trabalhos de soldadura em fábrica tendem a ser mais económicos e que o aparafusamento ocorre principalmente no local da obra (salvo situações especiais).

Esta solução é muito simples de fabricar e tende a ser pouco onerosa já que tem a vantagem de não ser necessário colocar parafusos sobre o perfil de suporte beneficiando o facto de, caso o perfil de suporte tenha uma viga no outro lado da alma (por exemplo, ligações com chapas de topo ou de dupla

cantoneira), não ter de partilhar parafusos. Este caso poderia dificultar o comportamento e resistência das ligações.

Por outro lado, é necessário ter alguns cuidados, pois não existe muita margem de erro para a sua montagem devido a sua furação prévia, que forçada pode levar a pré-esforços não calculados na sua modelação.

Existem algumas regras práticas de forma a cumprir os critérios de rotação, rigidez, ductilidade e estabilidade da ligação para ser considerada como uma ligação aparafusada articulada. (The Steel Construction Institute, 2014a)

Relativamente à estabilidade, ou seja, à restrição torsional e lateral define-se que:

- A chapa gousset deve estar posicionada o mais perto do banzo superior da viga suportada, por uma questão de restrição lateral;
- A chapa gousset não deve ter uma altura inferior a 0.6 vezes a altura da viga suportada, por uma questão de restrição torsional;
- Adicionar alguma rigidez (com utilização de chapas transversais a chapa de gousset).

Em relação à capacidade de rotação define-se que:

- A espessura da chapa de gousset ser menor do que 0.5 vezes o diâmetro dos parafusos;
- Utilização de parafusos da classe 8.8 sem pré-esforço;
- A componente condicionante em termos de resistência não deve ser uma componente frágil;
- O banzo da viga suportada nunca tocar no perfil de suporte.

Com estas definições asseguradas garante-se a atribuição de uma ligação aparafusada articulada, podendo se passar para a verificação de resistência e dos pressupostos assimilados.

2.3 CÁLCULO DA LIGAÇÃO

2.3.1 Disposições dos parafusos

As distâncias entre furos e bordas seguem um conjunto de regras (EC3 – 1-8: Quadro 3.3) baseados pela Figura e Tabela seguintes:




Fig. 4 - Disposição de furos e representação das distâncias

(Norma Portuguesa, 1993b)

Tabela 1 - Tabela resumo do Quadro 3.3

Distâncias	Valor mínimo	Valor máximo
e_1	$1.2 d_0$	$4t + 40$
e_2	$1.2 d_0$	$4t + 40$
p_1	$2.2 d_0$	$\min (14t; 200)$
p_2	$2.4 d_0$	$\min (14t; 200)$

Em que:

- e_1 – distância do parafuso ao bordo da chapa na direção de transmissão do esforço;
- e_2 – distância do parafuso ao bordo da chapa na direção perpendicular ao esforço;
- p_1 – distância entre parafusos na direção do esforço;
- p_2 – distância entre parafusos na direção perpendicular ao esforço;
- d_0 – diâmetro do furo;
- t – espessura do elemento mais fino a ligar.

Estas disposições garantem um bom funcionamento da ligação principalmente em relação ao esmagamento da chapa e ao controlo da influência da corrosão da ligação.

2.3.3 Capacidade de rotação

Como já referido anteriormente, é necessário garantir a capacidade de rotação da ligação de forma a esta poder ser considerada como articulada. Estas restrições passam pela limitação da altura da chapa gousset e da limitação do ângulo de rotação disponível.

Em relação à **altura da chapa**, esta tem de cumprir as seguintes restrições:

$$h_p \leq h_{perfil,2} - 2t_{f,2} - 2r_2 \quad (2.1)$$

$$h_p \geq 0.60 h_{perfil,2} \quad (2.2)$$

Em que:

- h_p – altura da chapa gousset;
- $t_{f,2}$ – espessura do banzo da viga suportada;
- r_2 – raio do cordão de ligação banzo-alma do perfil suportado;
- $h_{perfil,2}$ – altura do perfil suportado;

Em relação ao **ângulo de rotação disponível** (Figura 5), este tem de ser superior ao ângulo de rotação necessário.




Fig. 5 - Ângulo de rotação disponível consoante o momento aplicado

(*European Design Recommendations for Simple Joints in Steel Structures*, 2006)

De forma a cumprir a seguinte Equação:

$$\Phi_{disponível} > \Phi_{necessário} \quad (2.3)$$

O ângulo de rotação disponível pode ser obtido de duas formas:

$$\text{Se } z > \sqrt{(z - g_h)^2 + \left(\frac{h_p}{2} + h_e\right)^2} :$$

$$\Phi_{disponível} = \infty \quad (2.4)$$

Senão:

$$\Phi_{disponível} = \arcsin \left(\frac{z}{\sqrt{(z - g_h)^2 + \left(\frac{h_p}{2} + h_e\right)^2}} \right) - \arctg \left(\frac{z - g_h}{\frac{h_p}{2} + h_e} \right) \quad (2.5)$$

Em que:

- z – distância entre a alma do perfil de suporte e o centro geométrico dos parafusos;
- g_h – distância entre o perfil suportado e a alma do perfil de suporte;
- h_p – altura da chapa gousset;
- h_e – distância entre último parafusos e o banzo inferior da viga;

Já o **ângulo de rotação necessário** pode ser obtido pela seguinte Tabela, em que apresenta diferentes condições de carregamento:




Sistema de cargas	$M_{\max}$	$\phi_{\text{Necessário}}$
	M	$\phi_A = \frac{\gamma M L}{6 E I}$ $\phi_B = -\frac{\gamma M L}{3 E I}$
	$\frac{P L}{4}$	$\pm \frac{\gamma P L^2}{16 E I}$
	$\frac{p L^2}{8}$	$\pm \frac{\gamma p L^3}{24 E I}$
	$\frac{2 P L}{9 \sqrt{3}}$	$\phi_A = \frac{7 \gamma P L^2}{180 E I}$ $\phi_B = -\frac{8 \gamma P L^2}{180 E I}$

Fig. 6 - Ângulo de rotação necessário

(Teixeira Araújo Peixoto, 2008)

Caso o $\phi_{\text{disponível}}$ não seja superior ao $\phi_{\text{necessário}}$ o momento fletor considerado na ligação irá aumentar, como demonstrado pela Figura 5.

2.3.3 Ductilidade da ligação

Como já referido anteriormente, é necessário garantir certos critérios de ductilidade de forma a ligação poder ser considerada articulada. Isto corresponde a evitar modos de rotura frágil, garantindo uma redistribuição plástica interna de esforços à medida que a ligação sofre rotações.

De forma a evitar a **rotura frágil dos parafusos**, deve ser garantido que a resistência ao corte dos parafusos seja superior ao esmagamento na alma do perfil suportado ou da chapa, cumprindo a seguinte recomendação:

$$F_{V,Rd} \geq \min\{F_{b,Rd,w}, F_{b,Rd,p}\} \quad (2.6)$$

Em que:

- $F_{V,Rd}$ – Resistência ao corte dos parafusos;
- $F_{b,Rd,w}$ - Resistência ao esmagamento da alma do perfil suportado;
- $F_{b,Rd,p}$ - Resistência ao esmagamento da chapa gousset.

De forma a evitar a **rotura frágil do cordão de soldadura**, deve-se garantir que este tenha uma resistência igual ou superior à da chapa. Os valores devem ser comparados utilizando a resistência bruta da chapa com a resistência da soldadura pelo método simplificado, cumprindo a seguinte recomendação de espessura do cordão:

$$a_w \geq 0.5 t_p \beta_w \sqrt{3} \frac{f_y \gamma_{M2}}{f_u \gamma_{M0}} \quad (2.7)$$

Em que:

- a_w – espessura do cordão de soldadura;
- t_p – espessura da chapa gousset;
- β_w – fator de correlação para cordões de ângulo;
- f_y – tensão de cedência do aço;
- f_u – tensão de rotura do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções;
- γ_{M2} – coeficiente parcial de segurança para a resistência de secções à rotura.

Por fim, de forma a evitar a **fenómenos de instabilidade elástica** deve ser garantido que nenhuma verificação de segurança por instabilidade elástica seja a componente crítica da ligação.

2.3.2 Resistência ao corte dos parafusos

Nesta verificação idealiza-se um modo de rotura em que se analisa a resistência da ligação ao corte dos parafusos, em que estes resistem a esforços transversais à sua implementação, o chamada esforço de corte.




Fig. 7 - Resistência de corte de um parafuso

(BIC CONSTRUCTION ARCHITECTURAL JSC, n.d.)

O **valor de resistência de um parafuso ao corte ($F_{v,Rd}$)** por plano de corte, considerando que o corte ocorre na zona roscada (caso mais gravoso), pode ser obtido pela seguinte Equação (EC3 – 1-8: Quadro 3.4):

$$F_{v,Rd} = \frac{\alpha_v f_{ub} A}{\gamma_{M2}} \quad (2.8)$$

Em que:

- a_v – coeficiente considerando zona de corte e classe dos parafusos (EC3 – 1-8: Quadro 3.4);
- A – espessura da chapa gousset;
- f_{ub} – tensão de rotura dos parafusos;
- γ_{M2} – coeficiente parcial de segurança para a resistência de secções à rotura.

No caso de uma ligação apresentar mais do que um plano de corte como indicado na Figura 8, e que este tenha uma espessura (t_p) superior a um terço do diâmetro nominal dos parafusos (d), o valor de cálculo da resistência ao corte ($F_{v,Rd}$) deve ser multiplicado pelo coeficiente de redução segundo a Equação seguinte:




Fig. 8 - Influência dos planos de corte

(Zieliński Adam, 2008)

$$\beta_p = \frac{9d}{8d+3t_p} \text{ mas } \beta_p \leq 1 \quad (2.9)$$

De modo a obter resistência final ao corte do grupo de parafusos, o valor obtido deve ser multiplicado pelo número de parafusos existente na ligação.

O valor atuante pode ser calculado de diferentes formas, mas usualmente é calculado segundo o princípio da inércia polar, como representa a Figura 9.




Fig. 9 - Esquema de Inércia Polar dos parafusos

(MechaniCalc, 2023)

O valor da **inércia polar dos parafusos** (I_p) pode ser obtido segundo a expressão:

$$I_p = x_i^2 + y_i^2 \quad (2.10)$$

Em que:

- x_i – todas as coordenadas relativamente ao eixo x dos parafusos;
- y_i – todas as coordenadas relativamente ao eixo y dos parafusos.

Determinada a inércia polar dos parafusos consegue-se obter a força solicitada a cada parafuso, composta por uma **força horizontal (H)** e uma **força vertical (V)**. Para a obtenção do parafuso solicitado mais gravoso, é utilizada a combinação de forças que resulte na maior força resultante, generalizando-a para o grupo de parafusos, adotando um método conservativo. Os parafusos das extremidades opostas no qual as componentes vertical e horizontal estão na mesma direção correspondem a este caso mais gravoso, em que cada componente pode ser calculada segundo as equações:

$$H_{max} = \frac{N_{Ed}}{n} + \frac{M_{Ed}}{I_p} \times y_{max} \quad (2.11)$$

$$V_{max} = \frac{V_{Ed}}{n} + \frac{M_{Ed}}{I_p} \times x_{max} \quad (2.12)$$

Em que:

- n – número de parafusos;
- y_{max} – valor da ordenada y do parafuso mais afastado;
- x_{max} – valor da ordenada x do parafuso mais afastado;
- V_{Ed} – esforço transversal;
- N_{Ed} – esforço axial;
- M_{Ed} – momento fletor.

Assim, a **força resultante** resulta da seguinte Equação:

$$F = \sqrt{H^2 + V^2} \quad (2.13)$$

Esta força de corte solicitante por cada parafuso deve ser multiplicada pelo número total de parafusos, tal como o valor resistente anteriormente, para obter a componente total solicitante. Para verificar a segurança ao corte dos parafusos deve ser satisfeita a seguinte Equação:

$$F_{Ed} \leq F_{v,Rd} \quad (2.14)$$

2.3.3 Resistência ao esmagamento

Neste tipo de rotura analisa-se a resistência ao esmagamento dos elementos (vigas, chapas, contrachapa, pilares) exercido pelos parafusos. No caso de uma ligação aparafusada do tipo Fin-Plate, é

necessário analisar-se o esmagamento da alma do perfil suportado e o esmagamento da chapa, tanto na direção vertical como na direção horizontal.




Fig. 10 - Esmagamento originado por um parafuso

O **valor resistente ao esmagamento por um parafuso ($F_{b,Rd}$)** é calculado da seguinte forma (EC3 – 1-8: Quadro 3.4):

$$F_{b,Rd} = \frac{k_1 \alpha_b f_u d t}{\gamma_{M2}} \quad (2.15)$$

Em que:

- α_b, k_1 – coeficientes Tabelados (EC3 – 1-8: Quadro 3.4);
- t – espessura do elemento;
- d – diâmetro nominal dos parafusos;
- f_u – tensão de rotura do aço;
- γ_{M2} – coeficiente parcial de segurança para a resistência de secções à rotura.

Os coeficientes acima indicados têm de ser calculados ou atribuídos para cada direção e para cada elemento analisado, resultando no seguinte conjunto de forças resistentes:

- $F_{b,Rd,vertical,chapa}$;
- $F_{b,Rd,vertical,alma}$;
- $F_{b,Rd,horizontal,chapa}$;
- $F_{b,Rd,horizontal,alma}$.

De modo a obter a resistência total ao esmagamento da ligação os valores obtidos devem ser multiplicados pelo número total de parafusos

Os valores atuantes são as componentes da força resultante calculada anteriormente (2.13), em que para a resistência horizontal ao esmagamento, independentemente do elemento, compara-se à componente H da força resultante, e para a resistência vertical ao esmagamento, independentemente

do elemento, compara-se à componente V da força resultante, resultando no seguinte conjunto de condições:

$$V \leq F_{b,Rd,vertical,chapa} \quad (2.16)$$

$$V \leq F_{b,Rd,vertical,alma} \quad (2.17)$$

$$H \leq F_{b,Rd,horizontal,chapa} \quad (2.18)$$

$$H \leq F_{b,Rd,horizontal,alma} \quad (2.19)$$

2.3.4 Resistência ao corte

Neste tipo de rotura analisa-se a resistência ao corte dos elementos solicitados pelo esforço transversal, que para o caso de uma ligação aparafusada do tipo Fin-Plate é necessário analisar-se o corte relativamente à alma do perfil suportado e à chapa gousset. Para isso separa-se a verificação em dois possíveis cenários: um considerando a secção transversal bruta e outro considerando uma rotura em bloco, sendo a resistência ao corte total do elemento considerado correspondente ao mínimo entre estes dois cenários.




Fig. 11 - Rotura em bloco

(Norma Portuguesa, 1993b)

O valor da resistência para **cenário em que é considerada a área bruta da secção transversal** ($V_{pl,Rd}$) pode ser calculado segundo as seguintes equações:

- a) Secções de classe 1 ou 2, cálculo plástico (EC3 – 1-1: 6.18):

$$V_{pl,Rd} = \frac{A_v(f_y/\sqrt{3})}{\gamma_{M0}} \quad (2.20)$$

- b) Secções de classe 3 ou 4, cálculo elástico (EC3 – 1-1: 6.18):

$$\frac{\tau_{Ed}}{f_y/(\sqrt{3}\gamma_{M0})} \leq 1 \quad (2.21)$$

Em que:

- A_v – área de corte da secção transversal;
- f_y – tensão de cedência do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções;
- τ_{Ed} – tensão tangencial na alma;

A Equação 2.20 apresenta o valor da resistência ao corte, considerando uma abordagem para um cálculo plástico (**simplificação utilizada no documento SCI**), que para um caso mais rigoroso dever-se-ia determinar a classe da secção transversal, e caso faça parte da classe 3 ou da classe 4, adequar a resistência à Equação 2.21.

Para o cenário da resistência do elemento à **rotura em bloco** ($V_{block,Rd}$), a resistência pode variar entre:

- a) um carregamento centrado (EC3 – 1-8: 3.9):

$$V_{block,Rd} = \frac{f_u/A_{nt}}{\gamma_{M2}} + \frac{\left(\frac{1}{\sqrt{3}}\right)f_y A_{nv}}{\gamma_{M0}} \quad (2.22)$$

- b) um carregamento excêntrico (EC3 – 1-8: 3.10):

$$V_{block,Rd} = 0.5 \times \frac{f_u/A_{nt}}{\gamma_{M2}} + \frac{\left(\frac{1}{\sqrt{3}}\right)f_y A_{nv}}{\gamma_{M0}} \quad (2.23)$$

Em que:

- A_{nt} – área útil resistente à tração;
- A_{nv} – área útil resistente ao corte;
- f_y – tensão de cedência do aço;
- f_u – tensão de rotura do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções;
- γ_{M2} – coeficiente parcial de segurança para a resistência de secções à rotura.

Resultando no valor da **resistência ao corte final** ($V_{c,Rd}$):

$$V_{c,Rd} = \min (V_{pl,Rd} ; V_{block,Rd}) \quad (2.24)$$

Deste modo, a resistência ao corte, esta deve ser comparada com o esforço de corte, equivalente ao esforço transversal (V_{Ed}), satisfazendo a seguinte condição (EC3 – 1-1: 6.17):

$$V_{Ed} \leq V_{c,Rd} \quad (2.25)$$

2.3.7 Resistência à tração

Neste tipo de rotura analisa-se a resistência à tração dos elementos solicitados pelo esforço de tração. No caso de uma ligação aparafusada do tipo Fin-Plate é necessário avaliar em relação ao perfil suportado e à chapa gousset.




Fig. 12 - Rotura por tração
(AÇO-DIM, 2020)

O **valor da resistência à tração** ($N_{t,Rd}$) pode tomar os seguintes valores:

- a) Valor resistente plástico da secção bruta (EC3 – 1-1: 6.6):

$$N_{pl,Rd} = \frac{A f_y}{\gamma_{M0}} \quad (2.26)$$

- b) Valor resistente último da secção com furos (EC3 – 1-1: 6.7):

$$N_{u,Rd} = \frac{0.9 A_{net} f_u}{\gamma_{M2}} \quad (2.27)$$

- c) Valor resistente último da secção com furos para ligações da categoria C (EC3 – 1-1: 6.8):

$$N_{net,Rd} = \frac{A_{net} f_y}{\gamma_{M0}} \quad (2.28)$$

Em que:

- A – área bruta da secção;
- A_{net} – área útil da secção descontando os furos;
- f_y – tensão de cedência do aço;
- f_u – tensão de rotura do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções;
- γ_{M2} – coeficiente parcial de segurança para a resistência de secções à rotura.

Deste modo, a resistência à tração deve ser comparada com o **valor de tração atuante** (N_{Ed}), equivalente a esforço axial, de forma a satisfazer a seguinte Equação (EC3 – 1-1: 6.5):

$$N_{Ed} \leq N_{t,Rd} \quad (2.29)$$

Ainda assim, influência do esforço transversal aplicado na ligação deverá ser tida em conta para obter o valor da resistência à tração caso se verifique a seguinte situação:

$$V_{Ed} \leq 0.5 V_{pl,Rd} \quad (2.30)$$

Aplicando uma redução no valor da tensão de cedência igual a:

$$f_{y,reduzido} = (1 - \rho) f_y \quad (2.31)$$

Com o valor ρ igual a:

$$\rho = (2V_{Ed} / (V_{pl,Rd} - 1))^2 \quad (2.32)$$

2.3.7 Resistência à compressão

Neste tipo de rotura analisa-se a resistência à compressão dos elementos solicitados pelo esforço de compressão, que no caso de uma ligação aparafusada do tipo Fin-Plate é necessário avaliar em relação aos elementos: perfil suportado e chapa.




Fig. 13 - Rotura por compressão

(AÇO-DIM, 2020)

O valor da resistência à compressão ($N_{c,Rd}$) pode tomar os seguintes valores:

- a) Secções de classe 1, 2 ou 3 (EC3 – 1-1: 6.10):

$$N_{c,Rd} = \frac{A f_y}{\gamma_{M0}} \quad (2.33)$$

- b) Secções de classe 4 (EC3 – 1-1: 6.11):

$$N_{c,Rd} = \frac{A_{eff} f_u}{\gamma_{M0}} \quad (2.34)$$

Em que:

- A – área bruta da secção;
- A_{eff} – área da secção descontando os furos;
- f_y – tensão de cedência do aço;
- f_u – tensão de rotura do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções.

Deste modo, a resistência à compressão deve ser comparada com o **valor de compressão atuante** (N_{Ed}), de forma a satisfazer a seguinte Equação (EC3 – 1-1: 6.9):

$$N_{Ed} \leq N_{c,Rd} \quad (2.35)$$

Ainda assim, influência do esforço transversal aplicado na ligação deverá ser tida em conta para obter o valor da resistência à compressão caso se verifique a seguinte situação:

$$V_{Ed} \leq 0.5 V_{pl,Rd} \quad (2.36)$$

Aplicando uma redução no valor da tensão de cedência igual a:

$$f_{y,reduzido} = (1 - \rho) f_y \quad (2.37)$$

Com o valor ρ igual a:

$$\rho = (2V_{Ed} / (V_{pl,Rd} - 1))^2 \quad (2.38)$$

2.3.5 Resistência à flexão da chapa

Neste tipo de rotura analisa-se a resistência à flexão da chapa. Esta ocorre devido à excentricidade do esforço transversal aplicado a uma distância (z) do centro geométrico dos parafusos em relação à alma da viga de suporte.




Fig. 14 - Flexão originada por excentricidade de corte

O **valor da resistência à flexão da chapa ($M_{c,Rd}$)** pode tomar os seguintes valores:

a) Secções de classe 1 ou 2 (EC3 – 1-1: 6.13):

$$M_{c,Rd} = \frac{W_{pl} f_y}{\gamma_{M0}} \quad (2.39)$$

b) Secções de classe 3 (EC3 – 1-1: 6.14):

$$M_{c,Rd} = \frac{W_{el} f_y}{\gamma_{M0}} \quad (2.40)$$

c) Secções de classe 4 (EC3 – 1-1: 6.15):

$$M_{c,Rd} = \frac{W_{el,eff} f_y}{\gamma_{M0}} \quad (2.41)$$

Em que:

- W_{pl} – módulo plástico;
- $W_{el,min}$ – módulo elástico;
- $W_{eff,min}$ – módulo elástico efetivo;
- f_y – tensão de cedência do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções.

A Equação 2.40 apresenta o valor da resistência à flexão da chapa considerando uma abordagem para um cálculo elástico (**simplificação utilizada no documento SCI**), que para um caso mais rigoroso dever-se-ia determinar a classe da secção transversal, e caso faça parte da classe 1 ou 2 considera o módulo plástico W_{pl} , adotando a Equação 2.39, e caso seja de classe 4 considerar o módulo elástico efetivo $W_{eff,min}$ descontando os furos da chapa, adotando a Equação 2.41.

Determinada a resistência à flexão da chapa, esta deve ser comparada com o **valor da flexão atuante (M_{Ed})**, que é calculado multiplicando o esforço transverso pela distância da alma do perfil de suporte ao centro geométrico dos parafusos, como indica a Equação:

$$M_{Ed} = V_{Ed} \times z \quad (2.42)$$

A verificação é satisfeita se for garantida a seguinte condição (EC3 – 1-1: 6.12):

$$M_{Ed} \leq M_{c,Rd} \quad (2.43)$$

Ainda assim, influência do esforço transverso aplicado na ligação deverá ser tida em conta para obter o valor da resistência à flexão caso se verifique a seguinte situação:

$$V_{Ed} \leq 0.5 V_{pl,Rd} \quad (2.44)$$

Aplicando uma redução no valor da tensão de cedência igual a:

$$f_{y, reduzido} = (1 - \rho) f_y \quad (2.45)$$

Com o valor ρ igual a:

$$\rho = (2V_{Ed} / (V_{pl,Rd} - 1))^2 \quad (2.46)$$

2.3.6 Resistência à encurvadura devido à flexão

Neste tipo de rotura verifica-se a resistência à encurvadura lateral. Esta ocorre devido ao comprimento da chapa poder ser tão grande que, quando carregada, se gera uma encurvadura lateral em relação ao seu eixo de maior inércia solicitado à flexão, não tendo um travamento lateral que contraponha esta ação.




Fig. 15 - Torção lateral

O cálculo do **valor da resistência à encurvadura lateral ($M_{b,Rd}$)**, pode ser baseado segundo o documento SCI, que apresenta uma versão mais simples do problema, resultando na seguinte Equação:

$$M_{b,Rd} = \min \left(\frac{W_{el} f_y \chi_{LT}}{0.6 \gamma_{M1}} ; \frac{W_{el} f_y}{\gamma_{M0}} \right) \quad (2.47)$$

Em que o coeficiente de redução (χ_{LT}) é um valor Tabelado (Tabela 5.2 - SCI) consoante a esbelteza normalizada (λ_{LT}), que é obtida pela Equação:

$$\lambda_{LT} = \frac{2.8}{86.8} \left(\frac{z_p \times h_p}{1.5 t_p^2} \right)^{1/2} \quad (2.48)$$

Esta verificação é necessária apenas em casos que a chapa seja considerada como longa, definida pela condição:

$$z_p > t_p \quad (2.49)$$

Em que:

- z_p – distância do esforço transversal aplicado a primeira linha de parafusos;
- h_p – altura da chapa;
- t_p – espessura da chapa;
- W_{el} – módulo elástico da secção;
- f_y – tensão de cedência do aço.

Já segundo a parte 1-1 do EC3, o **valor do cálculo da resistência à encurvadura ($M_{b,Rd}$)** é um pouco mais complexo, seguindo os seguintes passos:

- 1- Cálculo do momento crítico para a encurvadura lateral

$$M_{cr} = C_1 \frac{\pi^2 E I_z}{(K L)^2} \left\{ \left[\left(\frac{k}{k_w} \right)^2 \frac{I_w}{I_z} + \frac{(K L)^2 G I_t}{\pi^2 E I_z} + [C_2 z_g - C_3 z_j]^2 \right]^{1/2} - [C_2 z_g - C_3 z_j] \right\} \quad (2.50)$$

- 2- Cálculo da esbelteza normalizada:

$$\lambda_{LT} = \sqrt{\frac{W_y f_y}{M_{cr}}} \quad (2.51)$$

- 3- Cálculo do fator Φ_{LT} :

$$\Phi_{LT} = 0.5 [1 + \alpha_{LT}(\lambda_{LT} - 0.2) + \lambda_{LT}]^2 \quad (2.52)$$

- 4- Cálculo do fator de redução:

$$\chi_{LT} = \frac{1}{\Phi_{LT} + \sqrt{\Phi_{LT}^2 - \lambda_{LT}^2}} \quad (2.53)$$

Deste modo, com todas as variáveis influentes calculadas, é possível obter o valor resistente pela seguinte Equação:

$$M_{b,Rd} = \chi_{LT} \frac{W_{el} f_y}{\gamma_{M1}} \quad (2.54)$$

Seguindo o documento EC3 ou o documento SCI, o valor resistente deve ser comparado com o **momento fletor atuante (M_{Ed})**, satisfazendo a seguinte Equação:

$$M_{Ed} \leq M_{b,Rd} \quad (2.55)$$

2.3.8 Resistência à flexão do entalhe

Neste tipo de rotura é analisada a resistência à flexão da viga na zona do entalhe (tornando esta verificação necessária apenas quando existem entalhes) na presença de esforço transversal.




Fig. 16 - Flexão da viga na zona do entalhe

(The Steel Construction Institute, 2014b)

O documento SCI especifica este tipo de rotura em que o **valor da resistência à flexão da zona entalhada ($M_{v,N,Rd}$)** pode tomar os seguintes valores:

- a) Para casos de a viga ser recortada apenas num banco:

$$M_{v,N,Rd} = \frac{f_y W_{eL,N}}{\gamma_{M0}} \quad (2.56)$$

- b) Para casos de a viga ser cortada nos 2 bancos:

$$M_{v,N,Rd} = \frac{f_y t_w}{6\gamma_{M0}} (e_{1,b} + (n_1 - 1)p_1 + h_e)^2 \quad (2.57)$$

Este valor da resistência deve ser comparado segundo o SCI com o **momento fletor atuante (M_{Ed})** que pode tomar os seguintes valores:

- a) Para casos de a viga ser recortada apenas num banco ou em dois bancos, mas com $x_n \geq 2d$:

$$M_{Ed} = V_{Ed}(g_h + l_n) \quad (2.58)$$

- b) Para casos de a viga ser cortada nos 2 bancos com $x_n \leq 2d$:

$$M_{Ed} = \max\{V_{Ed}(g_h + l_n); V_{Ed}(g_h + e_{2,b} + p_2)\} \quad (2.59)$$

Em que:

- g_h – distância da alma do perfil de suporte ao perfil suportado;
- h_e – altura entre o banco não cortado e o primeiro parafuso mais próximo;
- n_1 – número de linhas de parafusos;
- $e_{1,b}$ – distância do parafuso ao bordo do perfil suportado na direção do esforço;
- $e_{2,b}$ – distância do parafuso ao bordo do perfil suportado na direção perpendicular ao esforço;

- p_1 – distância entre parafusos na direção do esforço;
- p_2 – distância entre parafusos na direção perpendicular ao esforço;
- l_n – comprimento do entalhe;
- t_w – espessura da alma do perfil suportado;
- $W_{el,N}$ – módulo elástico da secção recortada em T;
- f_y – tensão de cedência do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções.

Deste modo, já tendo a resistência à flexão da alma na zona do corte e o momento atuante, deve ser satisfeita a seguinte Equação:

$$M_{Ed} \leq M_{v,N,Rd} \quad (2.60)$$

Ainda assim, influência do esforço transversal aplicado na ligação deverá ser tida em conta para obter o valor da resistência à flexão caso se verifique a seguinte situação:

$$V_{Ed} \leq 0.5 V_{pl,Rd} \quad (2.61)$$

Aplicando uma redução no valor da tensão de cedência igual a:

$$f_{y,reduzido} = (1 - \rho) f_y \quad (2.62)$$

Com o valor ρ igual a:

$$\rho = (2V_{Ed} / (V_{pl,Rd} - 1))^2 \quad (2.63)$$

2.3.8 Resistência da soldadura para um cordão de ângulo

Neste tipo de rotura verifica-se a resistência dos cordões de soldadura aos esforços solicitantes. No caso em específico de uma ligação aparafusada do tipo Fin-Plate para um cordão de ângulo. A sua verificação, **segundo o documento EC3**, pode ser obtido por 2 formas: pelo método direcional ou pelo método simplificado.




Fig. 17 – Cordão de ângulo

(Norma Portuguesa, 1993b)

Pelo **método direcional**, os esforços são decompostos em componentes paralelas e transversais ao eixo longitudinal da soldadura e, posteriormente, nos componentes perpendiculares e transversais ao plano do cordão. O **valor da resistência do cordão** é satisfeito se forem cumpridas as seguintes condições (EC3 – 1-1: 4.1):

$$[\sigma_{\perp}^2 + 3(\tau_{\perp}^2 + \tau_{\parallel}^2)]^{0.5} \leq f_u/(\beta_w \gamma_{M2}) \quad (2.64)$$

$$\sigma_{\perp} \leq 0.9 f_u/(\beta_w \gamma_{M2}) \quad (2.65)$$

Já pelo **método simplificado**, o cálculo é mais simples, calculando a **resistência de um cordão por unidade de comprimento** ($F_{w,Rd}$) pela seguinte Equação (EC3 – 1-1: 4.3):

$$F_{w,Rd} = f_{vw,d} a \quad (2.66)$$

Em que:

$$f_{vw,d} = \frac{f_u/\sqrt{3}}{\beta_w \gamma_{M2}} \quad (2.67)$$

Deste modo, já tendo a resistência do cordão deve ser comparado ao valor de cálculo do esforço atuante na soldadura por unidade de comprimento, satisfazendo a seguinte Equação:

$$F_{w,Ed} \leq F_{w,Rd} \quad (2.68)$$

Em que:

- $F_{w,Ed}$ – valor de cálculo do esforço atuante na soldadura por unidade de comprimento.

Já segundo o **documento SCI**, a verificação realizada na soldadura apenas garante que esta não é a componente mais fraca da ligação, se for garantida a seguinte condição:

- a) Para o aço S275:

$$a \geq 0.5 t_p \quad (2.69)$$

- b) Para o aço S355:

$$a \geq 0.6 t_p \quad (2.70)$$

2.3.9. Análise local da resistência à flexão da viga na zona dos parafusos

Neste tipo de rotura é analisada a resistência à flexão da viga na zona dos parafusos. Esta é uma análise local devido aos esforços de corte e flexão nas linhas de parafusos, podendo ocorrer um destacamento.




Fig. 18 - Análise local da zona dos parafusos à flexão

(The Steel Construction Institute, 2014b)

O documento SCI especifica este tipo de rotura em que o **valor da resistência à flexão da zona de parafusos** ($M_{c,BC,Rd}$) pode tomar o seguinte valor:

$$M_{c,BC,Rd} = \frac{f_y t_w}{6 \gamma_{M0}} ((n1 - 1)p_1)^2 + V_{pl,AB,Rd} (n1 - 1)p_1 \quad (2.57)$$

Em que:

- a) Para casos vigas com 1 coluna de parafusos:

$$V_{pl,AB,Rd} = \frac{t_w e_{2,b} \times f_y}{\sqrt{3} \gamma_{M0}} \quad (2.58)$$

- b) Para casos de vigas com 2 colunas de parafusos:

$$V_{pl,AB,Rd} = \frac{t_w (e_{2,b} + p_2) \times f_y}{\sqrt{3} \gamma_{M0}} \quad (2.59)$$

Este valor da resistência deve ser comparado segundo o SCI com o **momento fletor atuante** (M_{Ed}) que pode tomar os seguintes valores:

- c) Para casos vigas com 1 coluna de parafusos:

$$M_{Ed} = V_{Ed}(z_p) \quad (2.58)$$

- d) Para casos de vigas com 2 colunas de parafusos:

$$M_{Ed} = V_{Ed}(z_p + p_2) \quad (2.59)$$

Em que:

- $n1$ – número de linhas de parafusos;

- $e_{1,b}$ – distância do parafuso ao bordo do perfil suportado na direção do esforço;
- $e_{2,b}$ – distância do parafuso ao bordo do perfil suportado na direção perpendicular ao esforço;
- p_1 – distância entre parafusos na direção do esforço;
- p_2 – distância entre parafusos na direção perpendicular ao esforço;
- t_w – espessura da alma do perfil suportado;
- z_p – distância à primeira coluna de parafusos;
- f_y – tensão de cedência do aço;
- γ_{M0} – coeficiente parcial de segurança para a resistência de secções.

Deste modo, já tendo a resistência à flexão da alma na zona do corte e o momento atuante, deve ser satisfeita a seguinte Equação:

$$M_{Ed} \leq M_{c,BC,Rd} \quad (2.60)$$

Ainda assim, influência do esforço transversal aplicado na ligação deverá ser tida em conta para obter o valor da resistência à flexão caso se verifique a seguinte situação:

$$V_{BC,Ed} \leq 0.5 V_{pl,BC,Rd} \quad (2.61)$$

Aplicando uma redução no valor da tensão de cedência igual a:

$$f_{y,reduzido} = (1 - \rho) f_y \quad (2.62)$$

Com o valor ρ igual a:

$$\rho = (2V_{BC,Ed} / (V_{pl,BC,Rd} - 1))^2 \quad (2.63)$$

2.3.10. Estabilidade local de vigas com entalhe

Neste tipo de rotura é analisada a estabilidade local da viga devido aos entalhes caso esta não contenha elementos que restrinjam a encurvadura lateral. Não é obtida uma resistência, mas sim uma condição de comprimento e altura do entalhe.




Fig. 19 - Estabilidade local de vigas com entalhes

(The Steel Construction Institute, 2014b)

O documento SCI especifica este tipo de análise em que os **valores das condições para estabilidade do entalhe**, para o entalhe de maior dimensão (no caso da viga ter 2 entalhes), são as seguintes:

$$\max(d_{nt}; d_{nb}) \leq \frac{h_b}{5} \quad (2.57)$$

$$l_n \leq h_b \quad \text{para: } h_b/t_w \leq 54.3 \text{ (S275)} \quad (2.57)$$

$$l_n \leq \frac{160000h_b}{(h_b/t_w)^3} \quad \text{para: } h_b/t_w > 54.3 \text{ (S275)} \quad (2.57)$$

$$l_n \leq h_b \quad \text{para: } h_b/t_w \leq 48.0 \text{ (S355)} \quad (2.57)$$

$$l_n \leq \frac{110000h_b}{(h_b/t_w)^3} \quad \text{para: } h_b/t_w > 48.0 \text{ (S355)} \quad (2.57)$$

Em que:

- d_{nt} – altura do entalhe superior;
- d_{nb} – altura do entalhe inferior;
- l_n – comprimento do entalhe;
- t_w – espessura da alma do perfil suportado;
- h_b – altura da viga suportada.

2.3.11. Resistência ao corte da viga de suporte

Neste tipo de rotura é analisada a resistência ao corte da viga de suporte. Esta análise garante que o esforço de corte na zona da ligação com a chapa não excede o valor resistente.




Fig. 20 – Esforço de corte na viga de suporte

(The Steel Construction Institute, 2014b)

O documento SCI especifica este tipo de rotura em que o **valor da resistência ao corte da viga de suporte ($F_{v,Rd}$)** pode tomar o seguinte valor:

$$F_{v,Rd} = \frac{A_v f_y}{\sqrt{3}} \quad (2.60)$$

Deste modo, já tendo a resistência ao corte da viga de suporte, esta deve ser comparada com o esforço de corte atuante (V_{Ed}), satisfazendo a seguinte Equação:

$$V_{Ed} \leq F_{v,Rd} \quad (2.60)$$

Em que:

- A_v – área de corte ($h_p \times t_w$);
- f_y – tensão de cedência do aço.

3

MACHINE LEARNING NO CONTEXTO DO PROJETO DE ESTRUTURAS

3.1. MACHINE LEARNING

O “Machine Learning” é uma das ferramentas que surgiu com o desenvolvimento da inteligência artificial, sendo definida pela capacidade de um computador resolver um problema sem ser programado de forma explícita para o fazer. O objetivo é utilizar dados de entrada para obter um valor de saída esperado, mediante fórmulas matemáticas e métodos computacionais aplicados sobre os dados, procurando relações e padrões, de forma a obter uma previsão.

Existem diversas etapas que devem ser cumpridas antes da aplicação de um modelo de “Machine Learning”. Isso inclui a recolha, o armazenamento, a preparação e a análise dos dados. Em muitos casos, apenas a análise dos dados é suficiente para responder a certas questões ou resolver o problema em questão. Caso contrário, após ter finalizado estas etapas, prossegue-se para a fase de testar e usar diversos modelos de “Machine Learning” com intuito de obter as respostas procuradas.




Fig. 21 - Etapas para solucionar um problema por “Machine Learning”

Ao utilizar modelos de ML, é preferível começar a sua aplicação por modelos mais simples, que possam ser facilmente analisados e compreendidos por humanos. Todavia, se esses modelos não forem capazes de resolver o problema, é necessário aplicar modelos mais complexos na tentativa de encontrar um modelo que se adeque melhor aos dados e responda de forma mais precisa ao nosso problema.

Sendo assim, um projeto de “Machine Learning” aspira obter previsões de resultados com base numa base de dados sólida, que pode ser lida e interpretada por um modelo de ML.

3.2. MODELOS DE MACHINE LEARNING

Os modelos de “Machine Learning” podem ser divididos em categorias do tipo:

- “Supervised learning”;
- “Unsupervised learning”;
- “Reinforcement learning”.

A utilização destes pode ser a partir de modelos construídos manualmente ou através da importação de modelos fabricados, sendo esta a forma mais usual devido à vasta possibilidade de escolha. Estes ainda podem ser divididos em três grandes grupos:

- Modelos de Classificação – “Supervised ou Reinforcement learning”;
- Modelos de Regressão – “Supervised ou Reinforcement learning”;
- Modelos de “Clustering” – “Unsupervised learning”.

Em relação aos modelos de classificação, estes são adequados para situações em que se pretenda saber em que grupo uma determinada variável se insere, sendo útil para variáveis discretas e em casos que não existam muitos grupos a definir. Com base num conjunto de características, o modelo irá prever a que grupo se assemelha mais, podendo variar na forma de classificar. Os problemas de classificação podem ser divididos em problemas de classificação binária, que consiste na distinção entre duas classes, ou em problemas de classificação multi-classe, que consiste na distinção entre 3 ou mais classes.

Relativamente aos modelos de regressão, estes são adequados para casos em que se pretenda encontrar um padrão matemático e prever o valor de uma variável, sendo útil para variáveis contínuas. Consoante um conjunto de características, o modelo prevê que valor deve ser atribuído, sem uma restrição de valores, podendo variar na forma do calcular.

Os modelos de Clustering não serão abordados na presente dissertação por não serem utilizados. Dentro dos modelos de regressão e classificação existentes, foram aprofundados os seguintes:

- k-nearest Neighbors (Classificação ou Regressão);
- DecisionTree (Classificação ou Regressão);
- Linear Regression (Regressão);
- Random Forest (Classificação ou Regressão).

A seleção destes modelos tem por base procurar modelos simples (um princípio básico num projeto de “Machine Learning” que diz que, se um modelo simples conseguir representar os dados, este deve ser o escolhido), que não sejam uma caixa negra para o ser humano conseguir interpretar e que possam ser comparáveis na relação de métricas ou de número de parâmetros, como será demonstrado no tópico seguinte.(Jiang et al., 2022; Málaga-Chuquitaype, 2022)

3.2.1. k-nearest Neighbors

Este modelo de ML pode ser usado tanto para classificação quanto para regressão. O seu funcionamento baseia-se em procurar os k valores mais próximos no conjunto de dados de treino para fazer uma previsão para um valor desconhecido nesse mesmo conjunto de dados. Para classificação, o valor desconhecido encontra a classe que melhor se adequa, podendo esta variar dependendo do valor de vizinhos mais próximos que se considere, como é demonstrado pela Figura 22. O procedimento para regressão é o mesmo, mas, ao invés de se inserir o valor desconhecido numa classe, o modelo faz uma média dos valores dos vizinhos mais próximos para ponderar o seu resultado.

O modelo k-nearest Neighbors utiliza como hiper-parâmetros o número de valores (k) em torno do dado desconhecido e o peso de cada valor, isto é, valores mais próximos do dado desconhecido podem ter pesos superiores na previsão ou classificação em relação aos dados mais distantes. Portanto, alterando a base de dados, pode haver variações nos hiper-parâmetros mais adequados.

Este modelo apresenta algumas vantagens, como a simplicidade de implementação, o baixo número de hiper-parâmetros, a fácil interpretação e a capacidade de se adequar a diferentes conjuntos de dados de áreas distintas. No entanto, apresenta algumas desvantagens para conjuntos de dados que contenham classes distorcidas, pois, como é baseado em valores vizinhos, a classe que estiver em superioridade pode dominar a previsão. Outra desvantagem é que, para um conjunto de dados com muitas dimensões (muitas variáveis características), a distância mais próxima ao dado desconhecido se torna insignificante. Geralmente, é necessário aplicar uma redução de dimensionalidade para lidar com este problema, mas que em alguns casos, não é possível. (scikit-learn developers, 2023c)




Fig. 22 - k-nearest Neighbors

(Wikipedia, 2023a)

3.2.2. Linear Regression

O modelo de regressão linear é o mais usual e de maior facilidade na sua interpretação de todos, tendo sido o primeiro a ser construído e utilizado. Este modelo serve apenas para problemas de regressão e tenta traduzir por uma Equação, consoante as dimensões do problema, a relação entre os dados para um caso linear. O modelo linear regression, por norma, funciona, procurando a Equação que minimiza a distância dos mínimos quadrados de forma a ajustar, por exemplo, uma reta ou um plano o melhor possível aos dados, exemplificado na Figura 23. (scikit-learn developers, 2023b)

Este modelo tem a vantagem de não necessitar de nenhuma decisão de valores para os hiper-parâmetros, ainda assim pode-se utilizar alguns parâmetros sendo o principal o “fit_intercept”, cujo valor pode variar entre “true” ou “false”, dependendo se se quer obrigar que para valores de $x=0$ a base da Equação seja 0 ou se se quer o valor de base seja calculado.

As vantagens do modelo de regressão linear são a sua fácil interpretação (até pelo menos 3 dimensões), a não dependência de hiper-parâmetros, ao contrário da maioria de modelos, e daí não ser preciso adequar o modelo consoante novos dados de treino, e por fim a enorme quantidade de dados existente, principalmente ao nível de engenharia, que podem ser compreendidos por regressões lineares. No entanto, como todos os modelos, também apresenta algumas desvantagens como atribuir a mesma regressão linear para prever dispersões de dados muito diferentes, exemplificado na Figura 24, a tentativa de simplificar representações de dados mais complexos por simples regressões lineares, e também a previsão para valores de x altos poder sofrer um efeito de majoração errada (este acontecimento poder ser contrariado aplicando o efeito de Lasso).




Fig. 23 - Linear Regression

(Wikipedia, 2023c)




Fig. 24 - Mesma regressão para conjunto de dados diferentes

(Wikipedia, 2023c)

3.2.3. Decision Tree

Este modelo de ML pode ser usado tanto para classificação como para regressão. Este baseia-se em dividir o conjunto de dados em várias folhas, em que cada folha da árvore é rotulada com uma classe ou uma distribuição de probabilidade sobre as classes, o que significa que o conjunto de dados foi classificado pela árvore numa classe específica ou numa distribuição de probabilidade particular (que, se a árvore de decisão for bem construída, é inclinada para determinados subconjuntos de classes).

Para este modelo utilizou-se como hiper-parâmetros a profundidade da árvore aplicada, isto é a profundidade na procura da solução prevista que tem como objetivo regularizar a árvore ou limitar a forma com cresce, e o número mínimo de amostras que um nó deve conter para que a divisão seja considerada. Isto indica que alterando a base de dados pode haver variações nos parâmetros mais adequados. Existem outros parâmetros que podem influenciar a previsão final, mas que não são considerados nesta dissertação. (scikit-learn developers, 2023a)

O modelo de árvore de decisão tem algumas vantagens, tais como a capacidade de lidar com dados numéricos e categóricos, a sua fácil interpretação, podendo ser visualizada graficamente, como na Figura 26, e também não requerer muita preparação dos dados. Por outro lado, apresenta algumas desvantagens como a criação de árvores muito complexas representando bem os dados de treino levando a um efeito de “overfitting”, que é o ajuste ótimo aos dados de treino, mas para dados diferentes o modelo não se adequar e uma variação no conjunto de dados de treino pode originar árvores diferentes.




Fig. 25 - Decision Tree

(scikit-learn developers, 2023a)




Fig. 26 - Árvore de decisão

(scikit-learn developers, 2023a)

3.2.4. Random Forest

Este modelo de ML é uma combinação do modelo “decision tree”, que combina múltiplas e aleatórias árvores de decisão, exemplificado na Figura 27, com o intuito de tentar minimizar o erro resultante de apenas uma árvore. Pode ser usado para classificação como para regressão, tal como o decision tree. Para classificação o modelo encontrará a classe que o valor desconhecido deve fazer parte, consoante a classe que tiver sido escolhida pelo maior número de árvores de decisão. Para regressão o procedimento é o mesmo, mas em vez de o tentarmos inserir numa classe, o Random Forest faz a média dos valores obtidos por todas as árvores de decisão.

Este modelo utiliza como principais parâmetros a sua profundidade, tal como no modelo decision tree, e o número de árvores de decisão, diversificando as diferentes possibilidades de divisões de dados de partida iniciais. Isto indica que alterando a base de dados pode haver variações nos parâmetros mais adequados. Existem outros parâmetros que podem influenciar a previsão final, mas que não são considerados nesta dissertação.

Este modelo apresenta algumas vantagens como a capacidade de combater o “over-fitting” de uma só árvore de decisão, tendencialmente aumentando a precisão. Por outro lado, apresenta algumas desvantagens como a dificuldade de interpretação, ao contrário do modelo decision tree, além disso, é um modelo que consome muito a capacidade de memória RAM e que depende muito dos hiper-parâmetros atribuídos.




Fig. 27 - Random Forest

(Wikipedia, 2023b)

3.3. MÉTRICAS DE AVALIAÇÃO

Para realizar a comparação dos modelos existem muitas métricas para avaliar cada modelo que podem ser consultadas no link: https://scikit-learn.org/stable/modules/model_evaluation.html#multilabel-ranking-metrics. Devido ao elevado número de métricas existentes apenas serão abordadas em maior detalhe algumas, cuja escolha se baseou por serem de fácil interpretação e de rápida comparação. Existem métricas distintas para modelos de classificação e para modelos de regressão (Oliveira Júnior, 2021), sendo essa distinção explicada mais adiante.

Para aplicação das métricas selecionadas, foi utilizada a funcionalidade GridSearchCV, que realiza duas funcionalidades importantes. A funcionalidade de busca em grade (GridSearch) para procurar os melhores hiper-parâmetros dentro de uma gama de valores pré-definida para o modelo testado. Isto permite encontrar a combinação de hiper-parâmetros, que melhor se ajusta ao modelo em questão.

Além disso, o GridSearchCV também utiliza a funcionalidade de validação cruzada (CrossValidation) para minimizar o impacto da divisão entre dados de treino e de teste. O conjunto de dados de treino é dividido em k-folds (geralmente utilizando k-folds de 5), criando subgrupos de treino e teste, exemplificado na Figura 28. Dessa forma, é possível avaliar o desempenho do modelo em diferentes divisões dos dados e evitar que o modelo se ajuste excessivamente a um único conjunto de dados de treino.



Fig. 28 - Divisão em k-folds

(Shah, 2021)

Esta abordagem permite encontrar os melhores hiper-parâmetros considerando qualquer divisão dos dados e garantir uma avaliação mais robusta do desempenho do modelo, as métricas mencionadas nos próximos pontos.

3.3.1. Métricas para modelos de classificação

Accuracy

Esta é a métrica mais simples utilizada para modelos de classificação, que representa a razão entre o número de valores previstos corretamente sobre o número total de valores previstos. Tem uma desvantagem que é não fazer distinção entre classes, o que pode resultar, num caso com desequilíbrio entre classes, num modelo com boa accuracy porque acertou muito na classe maioritária, mas sem sucesso em acertar numa classe minoritária.

É calculada da seguinte forma:

$$Accuracy = \frac{TV}{TV + FV} \quad (3.1)$$

Em que:

- TV – número total de valores previstos com sucesso
- FV – número total de valores previstos erradamente

Matriz de confusão

De forma a colmatar as desvantagens da “accuracy”, a matriz de confusão consegue fazer uma análise por classes. Esta métrica indica a que classe cada valor foi atribuído, podendo assim ter uma visão geral da atribuição dos valores consoante a classe. Como podemos perceber pela Figura 29, os valores

da diagonal são os números de amostras atribuídas à classe correta e os outros valores foram o número de amostras atribuídas erradamente a outra classe.

[1 0 1 0]

[0 12 0 0]

[0 0 13 1]

[0 0 2 8]

Fig. 29 – Exemplo de resultados atribuídos às classes

Assim é possível calcular as seguintes métricas para cada classe, com a finalidade de produzir uma matriz com as seguintes métricas:

Precision

Razão entre os valores previstos corretamente da classe sobre a totalidade de valores verdadeiros dessa classe, medindo a percentagem de previsões positivas que realmente o são.

Calculada da seguinte forma:

$$Precision = \frac{VCS}{VCR} \quad (3.2)$$

Em que:

- VCS – número de valores previstos com sucesso da classe
- VCR – número de valores reais da classe

Recall

É a razão entre os valores previstos corretamente da classe sobre todos os valores atribuídos a essa classe, medindo a capacidade de prever valores corretos.

Calculada da seguinte forma:

$$Recall = \frac{VCS}{VCA} \quad (3.3)$$

Em que:

- VCS – número de valores previstos com sucesso da classe
- VCA – número de valores atribuídos da classe

F₁Score: é uma média harmónica entre estas duas métricas.

Calculada da seguinte forma:

$$F_1Score = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} \quad (3.4)$$

No fim, pode-se ainda fazer médias destes valores de diferentes formas, de forma a obter uma visão geral destas métricas sem ter que olhar para cada classe individualmente:

- “Macro averaging” – Corresponde à média das métricas sem ter em atenção número de amostras em cada classe;
- “Weighted Averaging” – Corresponde à média das métricas, mas ponderando o número de amostras que há em cada classe;

3.3.2. Métricas para modelos de regressão

Coefficiente de determinação - R²

Esta é uma das métricas mais comuns para análise de dados. Ao ser uma medida estatística que indica a proporção da variância total da variável dependente explicada pelo modelo de regressão. Esta pode ser vista como uma percentagem que a variável dependente depende da variável ou do conjunto de variáveis independentes.

É calculada da seguinte forma:

$$R^2 = 1 - (SSE / SST) \quad (3.5)$$

Em que:

- SSE – é a soma dos erros ao quadrado
- SST – é a soma dos quadrados das diferenças em relação à média

Erro médio absoluto – MAE

Esta métrica mede a diferença média entre os valores previstos e o valor real, considerando o módulo das diferenças. Por o resultado vir em termos absolutos, ou seja, na grandeza dos valores, não existe um valor considerado bom ou mau, mas sim em comparação com a média dos dados, por exemplo, é que se pode realmente ter uma noção do impacto que as falhas do modelo geraram.

É calculada da seguinte forma:

$$MAE = (1 / n) \times \sum |valor\ previsto - valor\ real| \quad (3.6)$$

Erro percentual médio absoluto – MAPE

Esta métrica mede a diferença percentual média absoluta entre os valores previstos e o valor real. Por o resultado vir em termos percentuais é de fácil comparação para diferentes conjuntos de dados.

É calculada da seguinte forma:

$$MAPE = (1 / n) \times \Sigma |(valor\ previsto - valor\ real) / valor\ real| \times 100 \quad (3.7)$$

Raiz do erro quadrático médio – RMSE

Esta métrica mede a raiz quadrada da média dos erros quadráticos entre as previsões do modelo e os valores reais. Ela proporciona uma análise diferente, ao dar mais peso a erros de maior dimensão por elevar os erros ao quadrado, diferenciando-se do MAE.

É calculada da seguinte forma:

$$RMSE = \sqrt{((1 / n) \times \Sigma ((valor\ previsto - valor\ real)^2))} \quad (3.8)$$

Estas foram as métricas escolhidas para avaliar os modelos de regressão, pois estas tinham de ser métricas de rápida percepção e fácil entendimento devido à elevada quantidade de variáveis a descobrir e ao número de modelos testados para cada uma, de forma a conseguir chegar ao objetivo final.

4

DESENVOLVIMENTO DE UM MODELO DE MACHINE LEARNING

4.1. CRIAÇÃO DA BASE DE DADOS

Como todos os casos de aplicação de modelos de “Machine Learning”, foi necessário proceder à recolha de dados, criando uma base de dados. Esta foi composta por três projetos de ligações metálicas realizadas pela bysteel de forma a preencher todas as variáveis características necessárias para aplicar um modelo de “Machine Learning” que dimensionasse uma ligação inteira do tipo Fin-Plate.

A bysteel forneceu uma Tabela num ficheiro Excel em que apenas apresentava as vigas a ligar e os esforços aplicados. Posto isto, foi necessário analisar os ficheiros AutoCAD com os detalhes de cada ligação, acrescentando colunas essenciais, tais como:

- Número de linhas de parafusos;
- Número de colunas de parafusos;
- Diâmetro dos parafusos;
- Altura da chapa;
- Espessura da chapa;
- Espessura da soldadura;
- Distâncias geométricas dos furos;
- Distância da excentricidade.

Ainda assim, foi necessário realizar o que é chamado de “*feature engineering*” que corresponde a reengenharia de variáveis. Isto envolve a reestruturação das variáveis existentes e a criação de variáveis que melhorem a compreensão ou até mesmo que possam ser vantajosas para o modelo de ML que se aplique. Começou-se por adicionar a altura e a espessura da alma da viga suportada, bem como a espessura da alma da viga de suporte, pois essas variáveis são relevantes para as verificações de segurança, e por isso poderão ser relevantes para o seu dimensionamento. Além dessas adições, foram criadas mais quatro variáveis, considerando o impacto que poderão ter no dimensionamento de uma ligação metálica. Essas variáveis são:

- “ $n \times d$ ” – Corresponde à multiplicação do número de parafusos pelo diâmetro dos mesmos;
- “ $n \times A$ ” – Corresponde à área total dos parafusos;
- “ $hp \times tp$ ” – Corresponde à área transversal da chapa;
- “ $hb - hp$ ” – Corresponde à diferença de altura da viga suportada e a altura da chapa.

Os dados foram armazenados num ficheiro Excel para permitir ajustes e refinamentos que poderiam levar a erros no nosso modelo. No entanto, não foram realizadas verificações de segurança em todas as ligações consideradas na base de dados, o que pode resultar em possíveis erros. Além disso, é importante mencionar que essas ligações não estão necessariamente otimizadas, o que significa que uma solução encontrada pelo modelo de ML pode não ser uma solução otimizada.

A quantidade de amostras necessárias depende do caso de estudo, da forma como os dados estão representados e da qualidade dos mesmos. Em geral, é recomendado ter pelo menos dez vezes o número de amostras relativamente ao número de colunas. No entanto, é importante ressaltar que cerca de 80% dos projetos de ML aplicados possuem mais de 1 milhão de amostras (Smolic, 2022).

Na base de dados deste projeto, após cortes e adições, totalizamos 126 linhas com dados de entrada, com o valor máximo de quatro colunas para a previsão de uma variável. Desta forma, conseguiu-se atender ao esse critério mínimo, embora isso não garanta totalmente a qualidade da base de dados. Com a análise de dados apresentada no próximo ponto, percebemos que o aumento da base de dados seria benéfico principalmente nos casos de classes ou gama de valores de uma variável esteja distorcido ou ainda, de forma a minimizar o impacto de um erro de dimensionamento estar contido na base de dados.

4.2. ANÁLISE DA BASE DE DADOS

Num projeto de Data Science, especialmente num projeto de “Machine Learning”, a fase mais importante é a análise dos dados. Nessa fase, são feitas conclusões e ajustes necessários à base de dados, de modo a aplicar modelos que possam prever resultados com a maior precisão possível.

Inicialmente, é realizada uma matriz de correlação, apresentada na Figura 30. Nesta etapa, procurou-se analisar a correlação entre uma variável e todas as outras, repetindo o processo para cada variável. É importante salientar que essa etapa proporciona uma visão geral da relação entre as variáveis, mas é necessário obter mais informações para determinar se uma variável é realmente dependente de outra, além da correlação visto, que esta não garante automaticamente uma relação ou não.

Após concluir a análise geral da relação entre variáveis, realizou-se uma análise individual de cada variável, com o objetivo de compreender como esta está representada no conjunto de dados, se há presença de “outliers” e as razões por trás da sua ocorrência, além de observar a sua distribuição, média e desvio padrão.




Fig. 30 - Matriz correlação de variáveis

Segundo Malawi Medical Journal, pode-se caracterizar os valores da correlação seguindo a Tabela abaixo (Malawi Medical Journal, 2012):

Tabela 2 - Caracterização de fatores de correlação

Fator correlação	Caracterização correlação
0.90 até 1.00	Muito alta
0.70 até 0.89	Alta
0.50 até 0.69	Moderada
0.30 até 0.49	Baixa
0.00 até 0.29	Nula

Com base na caracterização dos dados, decidiu-se realizar análises adicionais em todas as variáveis com um fator de correlação acima de 0.74, considerado alto ou muito alto. No entanto, **mesmo as variáveis com baixas correlações podem ter um impacto no valor de outra variável**, e com isso, uma análise mais específica será realizada quando necessário.

Para avaliar a dispersão dos dados em relação às variáveis de entrada, foi feita uma análise da altura da viga suportada relativamente à percentagem de esforço transversal em relação ao esforço resistente plástico da viga. Conforme se pode observar na Figura 31, os resultados abrangem uma ampla área, mas incluindo áreas com densidade de resultados menor. É importante referir que todos os modelos aplicados são mais adequados para vigas com alturas entre 100 mm e 600 mm e relações de esforço

transverso relativamente ao esforço plástico entre 0% e 35%. Acima ou abaixo desses valores, os modelos podem não estimar resultados com tanta precisão.




Fig. 31 - Dispersão da base de dados

4.2.1. Altura da viga suportada (h_{b1})

A altura da viga suportada é a primeira variável característica obtida a partir dos dados fornecidos pelo utilizador. Esta variável é considerada um "input" para o modelo de ML, uma vez que é totalmente baseada nas características da própria viga suportada.

Ao analisar o gráfico boxplot da variável h_{b1} na Figura 32, observou-se que os dados apresentam uma distribuição quase simétrica, com a mediana próxima ao centro do retângulo. No entanto, o retângulo está levemente mais próximo à parte superior, indicando uma ligeira predominância de amostras com alturas maiores. O desvio padrão dessa variável é de 129.75 mm, revelando uma grande dispersão consoante a ordem de grandeza da variável. A variável encontra-se compreendida entre 133 e 550 mm sendo este o intervalo de valores que se pode obter melhores conclusões.

No entanto, ao observar o gráfico de barras na Figura 33, constata-se que a base de dados abrange apenas 3% (equivalente a 4 amostras) de vigas com alturas compreendidas entre 533 e 612 mm. Isso indica uma falta de dispersão nessa faixa específica de alturas, podendo resultar em piores previsões para esta gama.




Fig. 32 - Boxplot altura da viga suportada (h_b)




Fig. 33 - Dispersão da altura da viga suportada (h_b)

4.2.2. Espessura da alma da viga suportada (t_{w1})

A espessura da alma da viga suportada também é considerada como um "input" fornecido pelo utilizador. Esta informação é considerada relevante para o modelo de ML, uma vez que é um dado fundamental baseado nas características específicas da viga suportada.

Ao analisar o gráfico de boxplot da variável t_{w1} na Figura 34, observa-se que os dados apresentam uma assimetria negativa, indicando uma maior concentração de dados com espessura de almas menores, com o retângulo próximo da parte inferior. O valor do desvio padrão é de 2.79 mm, revelando também uma grande dispersão nessa variável, considerando a ordem de grandeza dos dados. Além disso, a partir da interpretação do gráfico de boxplot, pode-se identificar a presença de "outliers", que correspondem aos valores que são 1.5 vezes maiores que o 3º quartil. A variável encontra-se compreendida entre 4.7 e 21.0 mm sendo este o intervalo de valores que se pode obter melhores conclusões.

Ao observar o gráfico de barras na Figura 35, reforça-se a ideia de uma falta de dados para faixas de espessuras de alma superiores. A base de dados apresenta apenas 2% de dados (equivalente a 2 amostras) para vigas com espessuras de alma entre 13.7 e 16.7 mm, 2% de dados (equivalente a 2 amostras) para vigas com almas compreendidas entre 19.7 e 22.7 mm, e nenhuma amostra compreendida entre 16.7 e 19.7 mm. Isso indica uma escassez de amostras nestas três classes, em que caso esta variável seja utilizada como input para previsão de uma outra, a má dispersão poderá ter impacto.





Fig. 34 - Boxplot da espessura da alma da viga suportada (t_w)

Fig. 35 - Dispersão da espessura da alma da viga suportada (t_w)

4.2.3. Esforço de corte ($V_{z,Ed}$)

O esforço de corte também é considerado um “input” para o modelo de ML, uma vez que é um dado mínimo necessário para realizar o dimensionamento de uma ligação metálica resistente às cargas solicitantes.

Ao analisar o gráfico boxplot da variável $V_{z,Ed}$ na Figura 36, observa-se que os dados estão assimétricos negativamente, pois o retângulo encontra-se mais próximo da extremidade inferior, indicando uma maior concentração de dados para esforços menores. A variável encontra-se compreendida entre 0 e 280 kN, sendo este o intervalo de valores que se pode obter melhores conclusões.

O valor do desvio padrão é de 87.96 kN, o que revela uma grande dispersão nessa variável, considerando a ordem de grandeza da mesma. De acordo com o gráfico de barras na Figura 37, verifica-se que apenas 5% dos dados (equivalente a 6 amostras) estão compreendidos entre 200 e 250 kN de esforço aplicado, havendo mais amostras para classes tendencialmente mais baixas.




Fig. 36 - Boxplot esforço de corte ($V_{z,Ed}$)




Fig. 37 - Dispersão esforço de corte (V_z)

4.3. ANÁLISE E MODELAÇÃO INDIVIDUAL DAS VARIÁVEIS

O objetivo da aplicação de modelos de ML para este conjunto de dados é para apenas com os “inputs” do nome da viga suporte (input convertido para altura da viga e espessura da alma), do nome da viga suportada (input convertido para altura da viga e espessura da alma) e do esforço de corte aplicado à ligação conseguir dimensionar todas as seguintes variáveis:

- Número de linhas de parafusos;
- Número de colunas de parafusos;
- Diâmetro dos parafusos;
- Distâncias geométricas dos furos;

- Espessura da soldadura;
- Altura da chapa;
- Espessura da chapa;
- Excentricidade do esforço imposto.

O processo envolve a criação de uma sequência lógica para a geração de variáveis, aplicando modelos sequencialmente e determinando cada variável uma de cada vez. Isto resultou na lógica representada na Figura 38, em que as variáveis a azul correspondem a variáveis estimadas por modelos de “Machine Learning”, e as variáveis a verde correspondem a variáveis descobertas por fórmulas matemáticas.




Fig. 38 - Descoberta sequencial de variáveis

Para realizar as análises entre variáveis **todos os dados foram normalizados**, isto é, todas as variáveis passaram para uma escala entre 0 e 1, tornando irrelevante a escala, seguindo a Equação 4.1. Este processo é de enorme importância tanto para a análise como para os modelos de machine learning escolhidos futuramente. Para além disso, em **cada análise entre variáveis normalizadas ordenou-se a base de dados por ordem crescente segundo uma das variáveis**, tornando assim as análises mais claras e perceptíveis, com o eixo x apenas a representar a organização da base de dados, não sendo relevante os seus valores. Para os gráficos de dispersão e gráficos de barras manteve-se a ordem de grandeza de cada variável para analisar-se os valores reais.

$$x \text{ (Normalizado)} = (x - x_{\min} / x_{\max} - x_{\min}) \quad (4.1)$$

4.3.1. Área total transversal dos parafusos ($n \times A$)

A primeira variável obtida neste projeto de “Machine Learning” é a área total transversal dos parafusos. Esta variável foi gerada anteriormente uma vez que se sabe, através de conhecimento na área e da análise de verificações de segurança, que é relevante no dimensionamento. Para a sua

previsão é utilizado apenas o esforço transversal (V_z), pelo que a relação entre estas duas variáveis é comprovada pela matriz de correlações (Figura 30), que apresenta um fator de correlação de 0.91, considerado muito alto.

Ao analisar a variável individualmente, verificou-se que o gráfico de barras (Figura 39) se assemelha ao apresentado pela variável V_z , indicando uma distribuição de dados semelhante, e que apenas 2% dos dados (equivalente a 2 amostras) estão compreendidos entre 4226 e 5226 mm², com superioridade de amostras para resultados tendencialmente menores, tal como acontece com a distribuição de V_z .




Fig. 39 - Dispersão área dos parafusos ($n \times A$)

Com isto, procurou-se analisar em maior detalhe a relação do esforço de corte (V_z) e a área total transversal dos parafusos ($n \times A$), conforme ilustrado pelas Figuras seguintes, uma vez que a partir dos dados tudo indicava que V_z podia ser uma boa variável para prever $n \times A$ para além do **conhecimento das variáveis influentes no dimensionamento dos parafusos**.




Fig. 40 - Variação das variáveis V_z e $n \times A$ normalizadas





Fig. 41 - Diferença das variáveis normalizadas

Pela figura 40 percebe-se que a evolução dos valores para ambas as variáveis apresentam claramente uma similaridade no seu aumento de valores. Para uma regressão perfeita, as diferenças entre as variáveis normalizadas corresponderiam sempre a valores de 0, e, pela figura 41, vê-se a proximidade das diferenças em relação ao eixo $y=0$, com valores à volta de $\pm 20\%$.

Fig. 42 - Relação $V_z - n \times A$

A partir da Figura 42 foi obtido o valor da métrica $R^2 = 0.83$ (ou 83%), que representa a precisão do ajuste da regressão linear consoante as duas variáveis, indicando a proporção percentual da variância dos dados explicada pela regressão linear. É possível perceber a existência de áreas de parafusos que podem estar sobredimensionadas para uma condição de esforço aplicado, resultando em outliers. Com base nessa interpretação, prosseguiu-se com a avaliação dos modelos de regressão previamente explorados, obtendo as seguintes métricas segundo a técnica de “cross validation”:

Tabela 3 - Comparação de modelos para $n \times A$

	LR	DTR	KNR	RFR
R^2	80%	76%	77%	73%
$R^2_{\min}$	73%	70%	71%	79%
$R^2_{\max}$	86%	79%	82%	79%


Após a análise realizada na Tabela 3, decidiu-se utilizar o modelo de regressão linear (LR). O motivo para essa escolha é que o modelo de regressão linear apresenta valores de precisão mais altos em comparação aos outros modelos considerados e, além disso, o modelo de regressão linear é uma abordagem mais simples e intuitiva, que não depende tanto de hiper-parâmetros, tornando-o menos suscetível a decisões prévias que afetem os resultados das previsões, como já abordado anteriormente.

4.3.2. Combinação do número de parafusos com o diâmetro dos mesmos ($n \times d$)

A segunda variável obtida neste projeto, seguindo a ordem sequencial arbitrada anteriormente, é a multiplicação do número de parafusos pelo diâmetro dos mesmos. Esta variável é dependente da variável V_z e da variável já prevista $n \times A$, e são estas duas consideradas na sua previsão. Estas relações são comprovadas pela matriz de correlações (Figura 30), apresentando um fator de correlação de 0.89 para V_z , considerado alto, e um a fator de correlação de 0.99 para $n \times A$, considerado muito alto.

É importante referir que ao utilizar uma variável previamente prevista por modelos de ML como input, podemos a estar a aumentar o erro de prever o seu valor real, tendo procurado minimizar este ponto com a não repetição de utilização de variáveis descobertas que não sejam tão necessárias ao longo do processo sequencial.

Ao analisar a variável individualmente, verificou-se que o gráfico de barras (Figura 43) se assemelha ao apresentado pela variável V_z e quase igual ao apresentado pela variável $n \times A$, o que indica uma distribuição de dados semelhante relativamente a estas duas variáveis, com apenas 2% dos dados (equivalente a 2 amostras) compreendidos entre 224 e 263.

Fig. 43 - Dispersão $n \times d$

Com isto, procurou-se analisar a relação entre a combinação prevista ($n \times d$) com o esforço de corte (V_z) e a área total transversal dos parafusos ($n \times A$), conforme ilustrado nas seguintes Figuras:




Fig. 44 - Variação das variáveis V_z , $n \times A$ e $n \times d$ normalizadas




Fig. 45 - Diferenças das variáveis normalizadas

Pela Figura 44 percebe-se que o aumento de valores é similar entre as 3 variáveis com uma maior proximidade da variável $n \times d$ à variável $n \times A$. Como evidenciado anteriormente, na Figura 45 constatou-se que as diferenças normalizadas estão muito próximas do 0, à volta de $\pm 5\%$, para a variável $n \times A$, não estando muito distantes para a variável $n \times d$, à volta de $\pm 10\%$. O facto de não se utilizar apenas a variável $n \times A$ para a previsão da variável $n \times d$ deve-se ao facto de a variável V_z ter algum impacto, ainda que seja pouco, na previsão do valor, podendo ajudar em casos de “desempate”.




Fig. 46 - Relação $n \times A$ - $n \times d$




Fig. 47 - Relação V_z - $n \times d$

A partir das Figuras 46 e 47 foram obtidos os valores das métricas $R^2 = 0.98$ (ou 98%) para a relação com $n \times A$ e $R^2 = 0.81$ (ou 81%) para a relação com V_z . Com base nessa interpretação, prosseguiu-se com a avaliação do modelo de regressão linear previamente explorado, obtendo as seguintes métricas segundo a técnica “cross validation”, que foram desde logo satisfatórias sem necessidade de explorar outros modelos:

Tabela 4 - Comparação de modelos para $n \times d$

	LR
R^2	96%
$R^2_{\min}$	96%
$R^2_{\max}$	97%

4.3.3. Número de parafusos (n)

Após ter descoberto a multiplicação do número de parafusos pelo diâmetro dos mesmos, o objetivo seria estimar o número de parafusos ou o diâmetro, uma vez que, ao descobrir uma, a outra variável poderia se obtida apenas por fórmulas matemáticas. Fazendo a análise das variáveis e a forma como se relacionam, concluiu-se que o melhor era estimar em primeiro lugar o número de parafusos. Analisando a matriz de correlação (Figura 30) retirou-se para possíveis variáveis de input a variável V_z com um fator de correlação de 0.79 e a variável $n \times d$ com um fator de correlação de 0.95.

A utilização da variável $n \times d$ em vez da variável $n \times A$ para determinar o número de parafusos justifica-se pelos resultados práticos obtidos terem sido significativamente melhores uma em relação à outra.

Ao analisar a variável individualmente, deduz-se que é considerada discreta (apesar de poder ser considerada continua por apenas se tornar discreta devido a questões de arredondamentos, mas relativamente ao cálculo estrutural os valores serem “contínuos”) o que nos poderia levar a modelos de classificação. Conforme o gráfico de barras da Figura 48, observa-se a existência de 6 classes um pouco distorcidas, com apenas 2% dos dados (equivalente a 2 amostras) a pertencerem à classe de 10 parafusos, apenas 2% dos dados (equivalente a 2 amostras) a pertencerem à classe de 2 parafusos e ainda 6% dos dados (equivalente a 8 amostras) a pertencerem à classe de 3 parafusos. Isto indica que para as classes de menor representatividade modelos de classificação poderiam apresentar alguns problemas, e por isso tentou-se atribuir modelos de regressão, com arredondamentos condicionados, de forma a colmatar possíveis erros.




Fig. 48 - Dispersão do número de parafusos (n)

Com isto, procurou-se analisar em maior detalhe a relação do número de parafusos (n) com o esforço de corte (V_z) e multiplicação do número de parafusos com o diâmetro dos mesmos ($n \times d$), uma vez que a partir dos dados tudo indicava podiam ser boas variáveis e **também por conhecimento das variáveis influentes no dimensionamento dos parafusos**, conforme ilustrado pelas seguintes Figuras:





Fig. 49 - Variação das variáveis normalizadas V_z , $n \times d$ e n (Parafusos)

Fig. 50 - Diferença das variáveis normalizadas

Pela Figura 49 percebe-se que o aumento de valores é similar entre as 3 variáveis com uma maior proximidade da variável $n \times d$ à variável n (Parafusos), como já era expectável. Como evidenciado anteriormente, na Figura 50 observa-se que as diferenças normalizadas estão próximas do 0, à volta de $\pm 12\%$, para a variável $n \times d$, não estando muito distantes para a variável V_z , à volta de $\pm 20\%$. A combinação das duas poderá servir como uma boa combinação para a previsão do número de parafusos, e por isso é analisado em maior detalhe estas relações nas seguintes Figuras:

Fig. 51 - Relação $n \times d$ – n parafusosFig. 52 - Relação V_z – n parafusos

A partir da Figura 51 foi obtido o valor da métrica $R^2 = 0.91$ (ou 91%), que representa a precisão a um ajuste de uma regressão linear para as duas variáveis comparadas. Já na Figura 52, ajustando uma regressão linear, o valor da métrica foi $R^2 = 0.63$ (ou 63%), o que não indica que não exista outra regressão adequada a estas duas variáveis. Com base nessa interpretação, prosseguiu-se com a avaliação de alguns modelos de classificação e de regressão (com aproximação), previamente explorados, obtendo as seguintes métricas de acordo com a técnica de “cross validation”:

Tabela 5 - Comparação de modelos para n parafusos

	LR	DTC	KNR	RFR
R^2	87%	87%	80%	90%
$R^2_{\min}$	80%	72%	60%	80%
$R^2_{\max}$	93%	96%	96%	98%

Após a análise realizada na tabela 5, decidiu-se utilizar o modelo Random Forest Regressor (RFR) com aproximação. O motivo para essa escolha é que o modelo apresenta valores de precisão mais altos

em comparação com outros modelos considerados tanto para um valor médio como para um valor máximo ou mínimo, representando bem o conjunto de dados existente.

4.3.4. Diâmetro (d)

O diâmetro dos parafusos, tal como referido anteriormente, é calculado apenas por cálculos matemáticos, pois a multiplicação do número de parafusos pelo diâmetro e o número de parafusos já são conhecidos, resultando no seguinte cálculo:

$$d = \frac{"n \times d"}{"n"} \quad (4.2)$$

4.3.5. Altura da chapa (h_p)

Após as características dos parafusos estarem determinadas, passou-se para as referentes à chapa. Começou-se por prever a altura da chapa utilizando, para variáveis independentes, a altura da viga suportada (h_b) e o esforço de corte (V_z). Estas foram as variáveis que a partir da matriz de correlações (Figura 30) se tomaram como possíveis inputs à previsão da altura da chapa com coeficientes de correlação de 0.95 e 0.79, respetivamente. A área total transversal dos parafusos poderia ter sido considerada como input, mas como se irá verificar em seguida, a sua utilização não foi necessária para atingir valores de métricas plausíveis, evitando assim a propagação de erros ao longo do processo sequencial, sendo uma variável prevista anteriormente.

Ao analisar a variável individualmente, verificou-se que o gráfico de barras (Figura 53) demonstra uma boa distribuição de dados, em que não apresenta falta de amostras para nenhuma gama da altura de chapas. Apesar desta variável estar muito correlacionada com a altura da viga suportada, esta não apresenta falta de valores para gamas superiores, indicando desde logo que não é a única variável a condicionar o seu valor futuro, garantindo ainda mais a necessidade de incorporar o esforço de corte.




Fig. 53 - Dispersão da altura da chapa

Com isto, procurou-se analisar em maior detalhe a relação da altura da chapa (h_p) com o esforço de corte (V_z) e com a altura da viga (h_b), uma vez que a partir dos dados tudo indicava podiam ser boas variáveis e **também por conhecimento das variáveis influentes no dimensionamento da chapa**, conforme ilustrado pelas seguintes Figuras:




Fig. 54 - Variação das variáveis normalizadas V_z , h_b e h_p




Fig. 55 - Diferença das variáveis normalizadas

Pela Figura 54 observa-se que o aumento de valores é similar entre as 3 variáveis com uma maior proximidade da variável h_p à variável h_p , como já era expectável. Contudo verifica-se que a subida do esforço também faz aumentar a altura da chapa. Segundo a Figura 55, concluiu-se que as diferenças normalizadas estão mais dispersas na previsão desta variável pelo que se espera que a união das 2 consiga fazer uma combinação suficientemente de forma a equilibrar esta variação, ou que uma regressão não linear se adeque ao conjunto de dados.




Fig. 56 - Relação h_b - h_p




Fig. 57 - Relação V_z - h_p

A partir da Figura 56 foi obtido o valor da métrica $R^2 = 0.76$ (ou 76%) para a relação com h_b , representando a precisão do ajuste por uma regressão linear para as duas variáveis comparadas, e na Figura 57 um $R^2 = 0.63$ (ou 63%) para a relação com V_z , valor que não representa bem a sua importância na previsão de h_p , podendo haver outra regressão que se ajuste melhor, ou ainda que a sua combinação com outras variáveis tenha impacto na previsão. Com base nessa interpretação, prosseguiu-se com a avaliação de alguns modelos de regressão, previamente explorados, obtendo as seguintes métricas segundo a técnica de “cross validation”:

Tabela 6 - Comparação de modelos para altura da chapa

	LR	DTR	KNR	RFR
R^2	92%	89%	88%	90%
$R^2_{\min}$	89%	78%	82%	85%
$R^2_{\max}$	97%	95%	94%	96%

Após a análise realizada na Tabela 6, decidiu-se utilizar o modelo Linear Regression (LR). O motivo para essa escolha é que o modelo apresenta valores de precisão mais altos em comparação com outros modelos considerados tanto para um valor médio com para um valor máximo ou mínimo, representando bem o conjunto de dados existente.

4.3.6. Área transversal da chapa ($h_p \times t_p$)

Após ter determinado a altura da chapa, como se tornou complicado encontrar uma forma de chegar diretamente à espessura da chapa, foi-se em busca da área transversal por ter mais variáveis que a pudessem influenciar na sua previsão. Para isso foram adotadas como variáveis independentes a altura da chapa (h_p), o esforço de corte (V_z) e ainda a área total dos parafusos ($n \times A$). Estas foram as variáveis, que a partir da matriz de correlações (Figura 30) se tomou como possíveis inputs à previsão da altura da chapa com coeficientes de correlação de 0.91, 0.83 e 0.91 e respetivamente.

Ao analisar a variável individualmente, verifica-se que o gráfico de barras da Figura 58 demonstra pouca densidade de amostras para as classes superiores, 1% dos dados (equivalente a 1 amostra) para áreas entre 7500 e 8499 mm², 0% dos dados (equivalente a 0 amostras) para áreas entre 8500 e 9499 mm² e 1% dos dados (equivalente a 1 amostra) para áreas entre 9500 e 10500 mm².




Fig. 58 - Dispersão da área transversal da chapa

Com isto, procurou-se analisar em maior detalhe a relação da área transversal da chapa ($h_p \times t_p$) com o esforço de corte (V_z), com a altura da chapa (h_p) e com a área dos parafusos ($n \times A$), uma vez que a partir dos dados tudo indicava podiam ser boas variáveis e **também por conhecimento das variáveis influentes no dimensionamento da chapa**, conforme ilustrado pelas seguintes Figuras:




 Fig. 59 - Variação das variáveis normalizadas V_z , $n \times A$, h_p e $h_p \times t_p$


Fig. 60 - Diferença das variáveis normalizadas

Pela Figura 59 percebe-se que o aumento de valores é similar entre as 4 variáveis com uma maior proximidade da variável $h_p \times t_p$ à variável V_z e à variável $n \times A$, surpreendentemente. Segundo a Figura 60, concluiu-se que as diferenças normalizadas estão mais dispersas para valores superiores, o que pode indicar que a previsão baseada nestas variáveis dependentes funciona melhor para coeficientes mais baixos, em que a proximidade à linha $y=0$ é de $\pm 10\%$ para todas as variáveis, exceto h_p , do que em coeficientes elevados, em que a proximidade à linha $y=0$ passa para $\pm 25\%$, exceto h_p . Com isto procurou-se analisar em maior detalhe a sua relação, resultando nas seguintes Figuras:




Fig. 61 - Relação $h_p - h_p \times t_p$




Fig. 62 - Relação $V_z - h_p \times t_p$




Fig. 63 - Relação $n \times A - h_p \times t_p$

A partir das Figuras acima analisou-se a relação entre cada uma das variáveis, vendo a sua influência ajustada por uma regressão linear para cada uma, tendo obtido o valor da métrica $R^2 = 0.84$ (ou 84%) para a relação com h_p , o valor da métrica $R^2 = 0.70$ (ou 70%) para a relação com V_z e o valor da métrica $R^2 = 0.84$ (ou 84%) para a relação com $n \times A$. Com base nessa interpretação, prosseguiu-se com a avaliação de alguns modelos de regressão, previamente explorados, obtendo as seguintes métricas segundo a técnica de “cross validation”:

Tabela 7 - Comparação de modelos de regressão para $h_p \times t_p$

	LR	DTR	KNR	RFR
R^2	85%	72%	82%	84%
$R^2_{\min}$	75%	28%	67%	56%
$R^2_{\max}$	94%	96%	92%	94%

Após a análise realizada na Tabela 7, decidiu-se utilizar o modelo Linear Regression (LR). O motivo para essa escolha é que o modelo apresenta valores de precisão mais altos em comparação com outros modelos considerados para um valor médio e mínimo, com uma diferença de apenas 2% para o valor máximo, representando bem o conjunto de dados existente.

4.3.7. Espessura da chapa (t_p)

Deste modo, a espessura da chapa é calculada, pois a previsão da altura da chapa e da sua área transversal já foram atribuídas. Este foi o processo com melhores probabilidades de obter o seu valor, pois por modelos de “Machine Learning”, com a base de dados existente, não era possível obter valores com tantas garantias, resultando no seguinte cálculo:

$$t_p = \frac{h_p \times t_p}{h_p} \quad (4.3)$$

4.3.8. Número de linhas de parafusos (n_1)

Após ter determinado as características dos parafusos e as características da chapa, passou-se para a previsão da disposição dos parafusos. Para isso foram adotadas como variáveis independentes a altura da chapa (h_p) e o número de parafusos (n) para a previsão do número de linhas de parafusos (n_1). Estas variáveis foram escolhidas principalmente **pelo conhecimento de fatores influentes à previsão do número de linhas**, com fatores de correlação de 0.69 (ou 69%) para o número de parafusos e 0.92 (ou 92%) para a altura da chapa.

Ao analisar a variável individualmente, verifica-se pelo gráfico de barras da Figura 64 que a variável é do tipo discreta (como era previsível), demonstrando poucos dados para a classe de 5 linhas de parafusos com apenas 2% dos dados (equivalente a 2 amostras). A falta de amostras para 5 linhas de parafusos pode condicionar a decisão da escolha de modelos por representar dados pouco homogêneos, podendo levar a erros em modelos de classificação.




Fig. 64 - Dispersão do número de linhas de parafusos (n1)

Com isto, procurou-se analisar em maior detalhe a relação do número de linhas de parafusos (n_1) com a altura da chapa (h_p) e o número de parafusos (n), uma vez que a partir dos dados tudo indicava podiam ser boas variáveis n e **também por conhecimento das variáveis influentes na distribuição dos parafusos**, conforme ilustrado pelas seguintes Figuras:




Fig. 65 - Variação das variáveis normalizadas n , n_1 e h_p

Pela Figura 65 percebe-se que o aumento de valores é similar entre as 3 variáveis, com uma maior proximidade da variável n_1 à variável n , por ambas serem variáveis discretas, mantendo os seus valores inalterados para condições características mais extensas (por exemplo para um intervalo de alturas da chapa entre 100 e 200 mm o número de linhas poderá ser duas ao longo de todo o intervalo).




Fig. 66 - Relação h_p - n_1




Fig. 67 - Relação n - n_1

A partir das Figuras acima analisou-se a relação entre cada uma das variáveis, vendo a sua influência ajustada por uma regressão linear para a altura da chapa (h_p) na Figura 66, tendo obtido o valor da métrica $R^2 = 0.85$ (ou 85%), apesar de utilizarmos um modelo de classificação. Para a relação com o número de parafusos (n), apresentada na Figura 67, apenas se observa como os dados eram classificados segundo esta variável. Com base nesta interpretação, prosseguiu-se com a avaliação de alguns modelos de classificação, previamente explorados, obtendo as seguintes métricas segundo a técnica de “cross validation”:

Tabela 8 - Comparação de modelos de classificação n_1

	KNC	RFC	DTC
Accuracy	90%	97%	98%
Accuracy min	72%	88%	92%
Accuracy max	96%	100%	100%

Após a análise realizada na Tabela 8, decidiu-se utilizar o modelo Decision Tree Classifier (DTC). O motivo para essa escolha é que o modelo apresenta valores de “accuracy” mais altos em comparação com outros modelos considerados tanto para um valor médio como para um valor mínimo ou máximo, sendo um modelo capaz de tomar boas previsões para todas as classes.

Este valor previsto é ainda condicionado pelo seguinte conjunto de condições de forma a garantir a simetria sugerida na disposição dos parafusos:

- Se $n = 10 \Rightarrow n1 = 5$;
- Se $n = 8 \Rightarrow n1 = 4$;
- Se $n = 6 \Rightarrow n1 = 6$ ou $n1 = 3$;
- Se $n = 5 \Rightarrow n1 = 5$;
- Se $n = 4 \Rightarrow n1 = 4$ ou $n1 = 2$;
- Se $n = 3 \Rightarrow n1 = 3$;
- Se $n = 2 \Rightarrow n1 = 2$.

4.3.9. Número de colunas ($n2$)

Desta forma o número de colunas é calculado, pois a previsão do número de parafusos e do número de linhas de parafusos já foram atribuídas. Este foi o processo com melhores probabilidades de obter o seu valor, pois por modelos de “Machine Learning”, com a base de dados existente, não era possível obter valores com tantas garantias, resultando no seguinte cálculo:

$$n2 = \frac{"n"}{"n1"} \quad (4.4)$$

4.3.10. Distância ao bordo livre do perfil suportado na direção do esforço (e_{1b})

Após ter determinado as características dos parafusos, as características da chapa e a organização dos parafusos, passou-se para a previsão das disposições geométricas dos furos. A variável inicial prevista foi a distância ao bordo do perfil suportado na direção do esforço (e_{1b}), isto de forma a garantir uma sequência possível para determinar todas as outras distâncias. A variável escolhida como input para a previsão foi a diferença de altura da viga suportada com a altura da chapa ($h_b - h_p$), esta que apresentava um fator de correlação segundo a Figura 28 de $R^2 = 0.79$ (ou 79%), considerado alto. Foram tentadas utilizar mais variáveis, mas sem trazer sucesso à aprendizagem de todos os modelos testados e por isso descartadas.

Ao analisar a variável individualmente, observou-se pelo gráfico de barras da Figura 68 que a variável pode ser considerada contínua, demonstrando poucos dados para gamas de valores superiores, com 1% dos dados (equivalente a 1 amostra) para valores entre 155 e 175 mm, e 2% dos dados (equivalente a 2 amostras) para valores entre 135 e 155 mm. Este dado é importante para a comparação das variáveis que se fará em seguida de forma a poder explicar o desvio das duas variáveis (h_b-h_p e e_{1b}) para valores elevados.




Fig. 68 - Dispersão da variável e_{1b}

Com isto, procurou-se analisar em maior detalhe a relação da diferença de altura da viga suportada com a altura da chapa (h_b-h_p) com a distância ao bordo livre da viga suportada (e_{1b}), **por conhecimento das variáveis influentes nas distâncias dos furos**, conforme ilustrado pelas seguintes Figuras:




Fig. 69 - Variação das variáveis normalizadas h_b-h_p e e_{1b}





Fig. 70 - Diferença das variáveis normalizadas

Pelas Figuras acima, percebe-se que estas duas se ajustam muito bem com uma distância ao eixo $y=0$ (regressão perfeita) com valores à volta de $\pm 10\%$, até chegar a um patamar que esta regressão perde valor e adequabilidade. Isto pode representar duas situações, uma em que os valores para dados superiores estão menos rigorosos ou que seria necessário aplicar dois modelos, um para dados menores e outro para dados superiores.

Fig. 71 – Relação $h_b-h_p - e_{1b}$

Segundo a Figura 71 reforça-se ainda mais que existe uma relação bem explícita entre estas duas variáveis com uma distorção para valores de diferença de alturas da chapa com alturas da viga superiores, afetando assim a métrica do R^2 apresentada na Figura como 0.63 (ou 63%). Assim tentou-se aplicar os modelos de regressão já abordados anteriormente, de forma a procurar o modelo que melhor se adequava, obtendo as seguintes métricas segundo a técnica de “cross validation”:


Tabela 9 - Comparação de modelos para e_{1b}

	LR	KNR	DTR	RFR
R^2	48%	72%	63%	71%
$R^2 \text{ min}$	14%	48%	46%	40%
$R^2 \text{ max}$	79%	90%	79%	86%

Pela Tabela acima vê-se que a métrica tem uma grande variância consoante o conjunto de dados e o conjunto de teste, isso demonstra uma vez mais que um só modelo pode não representar o desvio em cima já mencionado. Dentro dos modelos testados escolheu-se o modelo k-means Neighbors Regressor (KNR) pois era o que apresentava métricas mais altas. Esta medida geométrica tende a não ser tão relevante quanto as outras e ainda será corrigida mais adiante consoante o valor previsto para a distância ao bordo livre da chapa (e_1).

4.3.11. Distância ao bordo livre da chapa na direção do esforço (e_1)

Admitindo que a chapa é colocada centrada relativamente à alma do perfil suportado (como indicam as regras e como a nossa base de dados está representada) consegue-se obter a previsão para a variável e_1 .

Fig. 72 - Esquema do cálculo da variável e_1

Este foi o processo com melhores probabilidades de obter o seu valor, pois por modelos de “Machine Learning”, com a base de dados existente, não era possível obter valores com tantas garantias, resultando no seguinte cálculo:

$$e_1 = e_{1b} - \frac{h_b - h_p}{2} \quad (4.5)$$

Esta variável está ainda condicionada, pois os seus valores têm de ser múltiplos de 5 pelo qual arredondamos ao valor superior múltiplo de 5 a sua previsão. De forma a respeitar medidas geométricas e ser exequível, garantiu-se ainda que esta distância será sempre maior ou igual ao valor mínimo imposto pelo Eurocódigo 3, conforme apresentado no Capítulo 2.

4.3.12. Afastamento dos parafusos na direção do esforço (p_1)

Com a altura da chapa, a distância ao bordo livre da chapa na direção do esforço e o número de linhas de parafusos consegue-se obter diretamente o afastamento dos parafusos na direção do esforço pela seguinte Equação:

$$p_1 = \frac{(h_p - 2 \times e_1)}{n_1} \quad (4.6)$$

Esta variável está ainda condicionada, pois tem de ser valores múltiplos de 5, tal como a variável anterior, pelo qual arredondamos ao valor superior múltiplo de 5 a sua previsão. De forma a respeitar medidas geométricas e ser exequível, garantiu-se ainda que esta distância será sempre maior ou igual ao valor mínimo imposto pelo Eurocódigo 3, conforme apresentado no Capítulo 2.

4.3.13. Correções aos valores obtidos

Com os valores das variáveis calculados e_1 e p_1 , a altura da chapa e a distância ao bordo livre na direção do esforço da viga suportada poderão mudar ligeiramente, pelo que é importante reformular estes valores condicionados por estas medidas geométricas. Com isto as correções de valores resultaram em:

- Novo h_p :

$$"h_p" = 2 \times e_1 + (n_1 - 1) \times p_1 \quad (4.7)$$

- Novo e_{1b} :

$$e_{1b} = \frac{h_b - h_p}{2} + e_1 \quad (4.8)$$

4.3.14. Distância ao bordo livre da chapa na direção perpendicular ao esforço (e_2)

Após ter determinado as distâncias dos furos na direção do esforço, passou-se para a previsão das distâncias dos furos na direção perpendicular ao esforço. A variável inicial prevista foi a distância ao bordo da chapa na direção perpendicular ao esforço (e_2). As variáveis escolhidas como input para a sua previsão foram: o diâmetro (d) com um fator de correlação de 0.85 (ou 85%), a distância ao bordo livre da chapa na direção do esforço (e_1) com um fator de correlação de 0.77 (ou 77%) e a altura da viga (h_b) com um fator de correlação de 0.78 (ou 78%).

Ao analisar a variável individualmente, verifica-se pelo gráfico de barras da Figura 73 que a variável é considerada do tipo discreta, demonstrando poucos dados para a gama de valores baixos, totalizando 74% de amostras para as classes $e_2 = 40$ mm e $e_2 = 45$ mm em conjunto. Além disso, constata-se que existem apenas 2% de dados (equivalente a 2 amostras) para a classe de 20 mm e 3% de dados (equivalente a 4 amostras) para a classe de 25 mm.




Fig. 73 - Dispersão da variável e_2

Com isto, procurou-se analisar em maior detalhe a relação distância ao bordo livre da chapa na direção perpendicular ao esforço (e_2) com distância ao bordo livre da chapa na direção do esforço (e_1), com a altura da viga suportada (h_b) e com o diâmetro (d), conforme ilustrado pela seguinte Figura:




Fig. 74 - Variação das variáveis normalizadas e_1 , e_2 , d e h_b

Pela Figura acima, vê-se que a evolução das quatro variáveis ocorre mais ou menos simultaneamente, com uma maior nitidez para as 3 variáveis discretas, e_1 , e_2 e d por conseguirem manter valores condições características mais extensas, já explicado anteriormente.




Fig. 75 - Relação $d - e_2$




Fig. 76 - Relação $e_1 - e_2$




Fig. 77 - Relação $h_b - e_2$

Pelas Figuras 75 e 76 observa-se claramente que a variável e_2 é dependente das classes atribuídas ao diâmetro e à distância ao bordo livre da chapa na direção do esforço. Na Figura 77 essa percepção é mais complicada apenas por a variável h_b ser do tipo contínua, mas que revela o crescimento das duas variáveis com alguma dispersão de uma em relação à outra. Assim tentou-se aplicar os modelos de classificação já abordados anteriormente para procurar o modelo que melhor se adequava, obtendo as seguintes métricas segundo a técnica de “cross validation”:


Tabela 10 - Comparação de modelos para e_2

	KNC	RFC	DTC
Accuracy	72%	80%	79%
Accuracy min	64%	72%	68%
Accuracy max	84%	84%	92%

Dentro dos modelos testados escolheu-se o modelo Random Forest Classifier (RFC) pois, era o que apresentava métricas mais altas para valores médios e mínimos. Esta variável está ainda condicionada, devido aos seus valores terem de ser múltiplos de 5 pelo qual arredondamos ao valor superior múltiplo de 5 a sua previsão. De forma a respeitar medidas geométricas e ser exequível, garantiu-se ainda que esta distância será sempre maior ou igual ao valor mínimo imposto pelo Eurocódigo 3, conforme apresentado no Capítulo 2.

4.3.15. Distância ao bordo livre da chapa na direção perpendicular ao esforço (e_{2b})

Após a variável e_2 estar prevista, e antes de analisar a variável individualmente, procurou-se comparar como as variáveis e_2 e e_{2b} se relacionavam, tendo obtido o seguinte gráfico:

Fig. 78 - Dispersão da diferença das variáveis $e_2 - e_{2b}$

Pela Figura 78 concluiu-se que aplicar um modelo de classificação a esta variável seria inútil visto que 84% das amostras demonstram que a variável e_{2b} tem o mesmo valor que a variável e_2 , e por isso mantendo esta lógica, a sua previsão é resultado da Equação seguinte:

$$e_{2b} = e_2 \quad (4.9)$$

4.3.16. Afastamento dos parafusos na direção perpendicular ao esforço (p_2)

Para a previsão do afastamento dos parafusos na direção perpendicular ao esforço (p_2) começou-se desde logo por analisar a variável individualmente, resultando no seguinte gráfico de barras:




Fig. 79 – Dispersão da variável p_2

Pela Figura 79 constata-se que os valores estão concentrados em 2 classes: 42% na classe $p_2=60$ e 35% na classe $p_2=80$. Deste modo, e sabendo a influência que este valor tem no dimensionamento, atribuímos a esta variável um valor médio entre estas duas classes, pois seria desnecessário e pouco preciso procurar um modelo complexo para a previsão desta variável, resultando na seguinte Equação:

$$p_2 = 70 \quad (4.10)$$

De forma a respeitar medidas geométricas e ser exequível, garantiu-se ainda que esta distância será sempre maior ou igual ao valor mínimo imposto pelo Eurocódigo 3, conforme apresentado no Capítulo 2.

4.3.17. Espessura do cordão de soldadura (a)

Por fim, para determinar a espessura do cordão de soldadura, através de modelos de “Machine Learning” estudados e com a base de dados existente, não foram encontradas variáveis capazes de prever o seu resultado com valores de métricas aceitáveis. Outro fator de não utilizar um modelo de previsão para esta variável foi pela base de dados conter valores de espessuras de soldadura acima do

valor máximo recomendado pelas documentações existentes baseadas no Eurocódigo (abordado no Capítulo 2), como ilustra a Figura 80.




Fig. 80 - Variação das variáveis normalizadas a e t_{wmin}

Com isto, adotou-se o valor máximo recomendado, simplificando o processo, resultando na seguinte Equação:

$$a = 0.7 \times t_{wmin} \quad (4.11)$$

O valor da espessura do cordão de soldadura final é arredondado inferiormente, cumprindo assim o requisito imposto e garantindo uma espessura provável de cumprir as verificações de segurança.

4.5. CONCLUSÃO

Após executados todos os modelos para cada variável consegue-se prever o valor de cada uma e assim realizar um dimensionamento automático, com um nível de confiança atribuído a cada variável, o que facilita a interpretação de cada atribuição.

Este processo depende da forma sequencial decidida à priori e dos modelos a utilizar. Ainda assim, caso as variáveis estejam a ser bem previstas espera-se que os valores previstos por diferentes modelos, com níveis de confiança similares independentemente da ordem decidida de previsão de variáveis, consigam chegar a soluções similares.

Existem algumas condições em que este projeto poderá não dar resposta como os casos em que a decisão das vigas a ligar consoante o esforço de corte aplicado (dados característicos) estejam mal atribuídos desde logo, resultando nos seguintes acontecimentos:

- A disposição de parafusos prevista pode não ser possível de ser executada devido à altura da viga suportada;

- A altura da chapa prevista pode não ser possível de ser executada devido à altura da viga suportada;

Com isto, constata-se que é possível obter uma solução num processo de dimensionamento que, apenas com base em ligações realizadas anteriormente, é dimensionada por processos de “Machine Learning” com um nível de confiança atribuído.

5

DESENVOLVIMENTO DE UMA FERRAMENTA PARA O CÁLCULO DE LIGAÇÕES

5.1. CRIAÇÃO DO CÓDIGO (BACK END)

5.1.1. Criação do código de verificações

Em primeiro lugar, a parte mais importante da programação desta aplicação foi a de conseguir inserir todo o tipo de verificações de segurança necessárias a uma ligação do tipo Fin-Plate com todas as condicionantes impostas.

Para isso **foi utilizado principalmente o documento SCI** (baseado no Eurocódigo) em que se procurou repetir as verificações apresentadas para linguagem de programação. Este documento especifica em maior detalhe os possíveis modos de rotura que podem ocorrer a uma ligação do tipo Fin-Plate, resultando nas seguintes verificações necessárias:

- Recomendações geométricas;
- Resistência ao corte dos parafusos;
- Resistência ao esmagamento da chapa pelos parafusos;
- Resistência ao esmagamento da alma do perfil suportado pelos parafusos;
- Resistência ao corte da chapa;
- Resistência à flexão da chapa;
- Resistência à encurvadura da chapa;
- Resistência ao corte da alma do perfil suportado;
- Resistência à flexão da alma do perfil suportado com entalhe;
- Análise local à flexão da viga na zona aparafusada;
- Resistência à flexão da alma do perfil suportado na zona do entalhe;
- Estabilidade local para viga suportada com entalhe;
- Resistência da soldadura;
- Estabilidade local da viga de suporte.

Todas as verificações enumeradas acima foram seguidas pelo documento SCI à exceção da verificação da soldadura em que se adotou o método direcional presente no Eurocódigo 3. Todas as verificações são explicadas no Capítulo 2, sendo que **apenas foi considerado para esforços solicitantes o esforço transverso**, pois é o esforço que apresenta mais impacto na ligação, é o único considerado neste documento e por ter sido o único considerado no projeto de “Machine Learning” abordado no Capítulo 4.

A linguagem de programação escolhida foi **linguagem Python** por ser a linguagem mais utilizada atualmente, de mais fácil interpretação e por ser a linguagem recorrida para desenvolver os modelos de “Machine Learning” para fácil incorporação nesta aplicação como irá ser abordado mais adiante

```
# Shear - fin plate
# SCI
if dados_dict["n2"] == 1:
    Ant = dados_dict["tp"] * (dados_dict["e2"] - (d0 / 2))
else:
    Ant = dados_dict["tp"] * (dados_dict["p2"] + dados_dict["e2"] - 3 * (d0 / 2))

Anv = dados_dict["tp"] * (dados_dict["hp"] - dados_dict["e1"] - (dados_dict["n1"] - 0.5) * d0)
Avnet = dados_dict["tp"] * (dados_dict["hp"] - dados_dict["n1"] * d0)
Vrdg = dados_dict["hp"] * dados_dict["tp"] * fyp / (math.sqrt(3) * dados_dict["ym0"] * 1.27) * 10 ** -3
Vrdnet = Avnet * fup / (math.sqrt(3) * dados_dict["ym2"]) * 10 ** -3
Vrdb = ((0.5 * fup * Ant / dados_dict["ym2"]) + (fyp * Anv / (dados_dict["ym0"] * math.sqrt(3)))) * 10 ** -3
Vrdsci = min(Vrdg, Vrdb)
```

Fig. 81 - Peçaço de código de uma verificação de segurança

Foi criada uma função geral que engloba todas as verificações de segurança. Assim, quando esta for ativada, todas as verificações de segurança são calculadas originando todos os valores de resistência ou condições de segurança. Na Figura 81 podemos analisar o caso da verificação de segurança em relação ao corte da chapa em que todas as variáveis com o prefixo “dados_dict” são valores que tiveram de ser inseridos pelo utilizador, e os restantes são valores calculados ao longo da função.

5.1.2. Estrutura de dados

Quando se trabalha com dados ou aplicações devem ser utilizadas estruturas de dados universais. Para a criação desta aplicação recorreu-se ao **tipo JSON** (JavaScript Object Notation) que “é uma formatação de dados leve de troca de dados. Para seres humanos, é fácil de ler e escrever. Para máquina, é fácil de interpretar e gerar.”(Introdução Ao JSON, n.d.). Este é um dos formatos mais usados por grandes empresas a nível mundial pois usa convenções triviais para diferentes tipos de linguagem de programação, podendo rapidamente ser utilizado para outro fim que não o desenhado inicialmente.

Em JSON, os dados são apresentados da seguinte forma: um objeto que é um conjunto desordenado de pares nome/valor, começando com “{” e termina com “}”; cada nome é seguido por “:” e os pares nome/valor são seguidos por “,”. Esta estrutura de dados é muito similar à estrutura de dados segundo um dicionário Python, como é exemplificado na Figura 82.

```

Shear_fin_plate = {
  "Fin Plate in Shear": {
    "EC": {
      "Esforço imposto": {"Ved": dados_dict["ved"]},
      "Esforço resistente": {"Vrd,c": Vrdc}
    },
    "SCI": {
      "Esforço imposto": {"Ved": dados_dict["ved"]},
      "Esforço resistente": {"Vrd,c": Vrdsci}
    }
  }
}

```

Fig. 82 - Estrutura de dados JSON

Todos os ficheiros e pedidos de informação necessários comunicam entre si com esta estrutura de dados, recebendo parâmetros no formato JSON, carregando para o formato de um dicionário Python (estrutura de dados muito similar com o formato JSON, lida pela linguagem Python) para poder ser acedida e utilizada, dando como resposta final um dicionário Python, passando para uma estrutura de dados JSON também. Este processo é recorrente em todas as trocas de informação, ou seja, em todas as funções ativadas, podendo sempre ser acessíveis e utilizados para outro fim desejado.

Para se aceder ao esforço resistente da chapa ao corte segundo o SCI, após estar convertido de JSON para dicionário Python, é apenas necessário incluir a localização do valor da seguinte forma: `dados_dict["Fin Plate in Shear"]["SCI"]["Esforço resistente"]["Vrd,c"]`, em que “dados_dict” é o nome do dicionário que contém todos os valores.

5.2. CRIAÇÃO DE UMA “INTERFACE” (FRONT END)

Após o código das verificações de segurança estar completo passou-se para a criação de uma interface gráfica que fosse visualmente atrativa e simples de usar, de modo que qualquer pessoa sem qualquer instrução a conseguisse utilizar.

Para montar esta interface utilizou-se a biblioteca “Pyqt5” que incorpora uma funcionalidade que é o comando “Designer”. Esta permite desenvolver uma interface mais apelativa e funcional do ponto de vista do utilizador sem ter de escrever o código todo manualmente, apenas ajustando e adicionando alguns pormenores escritos diretamente no código.




Fig. 83 - Comando "Designer" para criação de janelas gráficas

Esta interface é composta por seis páginas no total, sendo que cinco são destinadas para o utilizador inserir os dados referentes à ligação e a última destinada a apresentar os resultados das verificações de segurança. Os dados pedidos ao utilizador são os mínimos necessários para se conseguir realizar todas as verificações de segurança da ligação viga-viga, nomeadamente:

- Coeficientes de segurança;
- Vigas utilizadas;
- Resistência do aço dos perfis e da chapa gousset;
- Esforços impostos;
- Geometria dos furos;
- Dimensões da chapa;
- Classe dos parafusos;
- Diâmetro dos parafusos;
- Número de linhas e colunas de parafusos;
- Espessura do cordão de soldadura;
- Informações dos entalhes.

As páginas para introduzir valores foram divididas pelo seguinte formato:

1. Informações gerais:
 - Coeficientes de segurança;
 - Perfis Metálicos.

MainWindow

File Edit

Gerais Resistências \ Esforços Geometria Ligações Elementos de ligação Recortes RESULTADOS

VIGA 2 VIGA 1 VIGA SUPORTE

COEFICIENTES DE SEGURANÇA

Y_{10} 1.00
 Y_{11} 1.00
 Y_{12} 1.25

PERFIS METÁLICOS

Viga suporte: IPE750x220
 Viga suportada 1: IPE750x220
 Viga suportada 2: None
 (Caso exista segunda viga)

Próximo

Fig. 84 - Página 1 da interface

2. Resistências e Esforços:

- Classe do aço para os perfis e para a chapa gousset;
- Esforços impostos.

MainWindow

File Edit

Gerais Resistências \ Esforços Geometria Ligações Elementos de ligação Recortes RESULTADOS

V102 V101 N101

RESISTÊNCIA AÇO

Class aço, Supporting: S275
 Class aço, Supported: S275
 Class aço, Chapa: S275

ESFORÇOS IMPOSTOS

Esforço transversal, V_{101} (kN): 0
 Esforço transversal, V_{102} (kN): 0
 Esforço axial, N_{101} (kN): 0
 (Caso exista segunda viga)

Anterior Próximo

Fig. 85 - Página 2 da interface

3. Geometria da ligação:

- Geometria dos parafusos;
- Geometria da chapa.




Fig. 86 - Página 3 da interface

4. Elementos da ligação:
- Características dos parafusos;
 - Características do cordão de soldadura.




Fig. 87 - Página 4 da interface

5. Informações dos entalhes:
- Tipo de entalhe;
 - Distâncias do entalhe.




Fig. 88 - Página 5 da interface

Assim que o utilizador preenche todos os campos essenciais para fazer as verificações de segurança programadas, este poderá com um clique, aceder na última página aos resultados dessas verificações.




Fig. 89 - Página 6 da interface

Deste modo o processo desta aplicação segue a seguinte lógica:

- 1- Utilizador insere na interface as variáveis de entrada necessários para o cálculo das verificações de segurança, em todas as páginas destinadas, como explicado anteriormente;

- 2- Utilizador clica no botão “Verificar” da página 6 para calcular as verificações de segurança;
- 3- **Função “salvar_valores”** é ativada e recebe como parâmetros de entrada os dados inseridos pelo utilizador, convertendo num dicionário Python chamado “valores”, respondendo como parâmetros de saída o dicionário “valores” numa estrutura de dados JSON;

```
def salvar_valores(self):
    valores = {
        "perfil": str(self.Supported1.currentText()),
        "perfil_suporta": str(self.Supporting.currentText()),
        "ved": float(self.Travers_Ved1.text()),
        "N": float(self.Ned1.text()),
        "classe_chapa": str(self.Class_aco_chapa.currentText()),
        "classe_perfil": str(self.Class_aco_supp.currentText()),
        "classe_perfil_supporting": str(self.Classee_aco_Supporting.currentText()),
        "classe": float(self.classe.currentText()),
        "d": float(self.dn.currentText()),
        "n1": float(self.n1.text()),
        "n2": float(self.n2.text()),
        "e1": float(self.e1.text()),
        "e2": float(self.e2.text()),
        "p1": float(self.p1.text()),
        "p2": float(self.p2.text()),
        "e1b": float(self.e1b.text()),
        "e2b": float(self.e2b.text()),
        "tp": float(self.tp.text()),
        "hp": float(self.hp.text()),
        "ym2": float(self.Ym2.value()),
        "ym0": float(self.Ym0.value()),
        "ym1": float(self.Ym1.value()),
        "gh": float(self.gh.text()),
        "notched": str(self.notched.currentText()),
        "ln": float(self.ln.text()),
        "xn": float(self.xn.text()),
        "dnt": float(self.dnt.text()),
        "dntb": float(self.dntb.text()),
        "a": float(self.a.text()),
        "Ved2": float(self.Traverso_Ved2.text()),
        "hp2": float(self.hp2.text())
    }
    return json.dumps(valores)
```

Fig. 90 - Função "salvar valores"

- 4- **Função “verificações_segurança”** é ativada e recebe a estrutura de dados JSON anterior (contendo as variáveis de entrada), converte num dicionário Python chamado “dados_dict”, calcula as verificações de segurança, estrutura resultados das verificações num dicionário Python chamado “dicionário_total”, respondendo como parâmetros de saída o dicionário “dicionário_total” numa estrutura de dados JSON;

```
def verificacoes_geral(arg):
    dados_dict = json.loads(arg)
```

Fig. 91 - Conversão da estrutura de dados JSON de entrada para um dicionário Python

```
# Lateral Torsional buckling - fin plate
# SCI

zp = dados_dict["e2b"] + dados_dict["gh"]

if zp > dados_dict["tp"] / 0.15:
    llt = (2.8 / (93.9 * math.sqrt(235 / fyp))) * (((dados_dict["e2b"] + dados_dict["gh"]) * dados_dict["hp"]) /
    (1.5 * dados_dict["tp"] ** 2)) ** 0.5
    Xlt = 0.1698 * llt ** 2 - 0.8315 * llt + 1.1446
    Vrdlt = min(Wel * Xlt * fyp / (z * 0.6 * dados_dict["ym1"]) * 10 ** -3, Wel * fyp / (z * dados_dict["ym0"]) * 10 ** -3)
else:
    Vrdlt = Wel * fyp / (z * dados_dict["ym0"]) * 10 ** -3

# EC
llt = (2.8 / (93.9 * math.sqrt(235 / fyp))) * (((dados_dict["e2b"] + dados_dict["gh"]) * dados_dict["hp"]) /
    (1.5 * dados_dict["tp"] ** 2)) ** 0.5
Xlt = 0.1698 * llt ** 2 - 0.8315 * llt + 1.1446
Mltrd = Xlt * Mcrddb
```

Fig. 92 - Exemplo de uma verificação de segurança

```
L_T_B_fin_plate = {
    "Lateral Torsional Buckling - Fin Plate": {
        "EC": {
            "Esforço imposto": {"Med": M},
            "Esforço resistente": {"Mrd,lt": Mltrd}
        },
        "SCI": {
            "Esforço imposto": {"Ved": dados_dict["ved"]},
            "Esforço resistente": {"Vrd,lt": Vrdlt}
        }
    }
}
```

Fig. 93 - Exemplo do "dicionário total" para uma verificação

```
dicionario_total = {**Geometria, **Bolt_Shear, **Bolt_bearing, **Shear_fin_plate,
    **Bending_fin_plate, **L_T_B_fin_plate,
    **Web_Shear, **Web_Shear_notched, **Resistance_connection,
    **Resistance_notch,
    **Lcl_stab_notched_b, **Welds, **Supporting}

print(json.dumps(dicionario_total))
return json.dumps(dicionario_total)
```

Fig. 94 - Conversão do "dicionário total" em uma estrutura de dados JSON

- 5- **Função “resultados”** é ativada e recebe a estrutura de dados JSON anterior (contendo as verificações de segurança), convertendo num dicionário Python chamado “dados_dict” como parâmetros de saída;

```
def resultados(arg):
    dados_dict = json.loads(arg)
```

Fig. 95 - Conversão da estrutura de dados JSON com os resultados em um dicionário

- 6- Interface recebe o dicionário e apresenta da forma estipulada na página 6 os resultados de forma a estes serem legíveis;

5.3. INCORPORAÇÃO DO MODELO DE MACHINE LEARNING

Com a aplicação de verificações de segurança concluída foi decidido incorporar o modelo de “Machine Learning” desenvolvido no Capítulo 4 na aplicação de modo a conseguir gerar ligações metálicas de forma mais rápida e ver se estas passam nas verificações de segurança. Deste modo, para além das métricas avaliadas consegue-se aferir verdadeiramente sobre a sua eficácia.

Para isso instalou-se um botão na página 3 da interface, pois os dados referentes às vigas pertencentes da ligação e o esforço transversal aplicado já foram definidos pelo utilizador, podendo agora este obter as sugestões das outras componentes da ligação pela previsão das variáveis segundo o modelo de “Machine Learning”.

Todos os modelos utilizados foram gravados em um ficheiro individual para serem acedidos com os parâmetros e processos prévios já totalmente definidos. Desta forma a integração na ferramenta passa a ser possível sem necessitar de repetir inúmeras vezes passos desnecessários.

Desta forma o utilizador pode verificar a segurança de uma ligação metálica para uma ligação já dimensionada ou para uma ligação que pretende dimensionar. Os modelos de “Machine Learning” foram gravados e inseridos dentro de uma função de modo a serem combinados segundo a mesma lógica da estrutura de dados referida anteriormente.

É importante referir que a base de dados apenas contém vigas sem entalhe pelo que as soluções geradas nunca irão considerar uma solução com entalhe.




Fig. 96 - Incorporação do Machine Learning

- 1- Utilizador insere na interface as 3 variáveis de entrada necessárias para estimar as variáveis restantes através do “Machine Learning” como já foi abordado anteriormente;
- 2- Utilizador clica no botão “Machine Learning” da página 3 para estimar as restantes variáveis;

- 3- Função “**salvar_parametros**” é ativada e recebe como parâmetros de entrada os dados inseridos pelo utilizador, convertendo num dicionário Python chamado “parametros”, respondendo como parâmetros de saída o dicionário “parâmetros” numa estrutura de dados JSON;

```
def salvar_parametros(self):
    parametros = {
        "perfil": str(self.Supported1.currentText()),
        "perfil_suporta": str(self.Supporting.currentText()),
        "Ved": float(self.Tranvers_Ved1.text())
    }
    arg = json.dumps(parametros)
    return arg
```

Fig. 97 - Função guardar parâmetros necessário para Machine Learning

- 4- Função “**modelos_corridos**” é ativada e recebe a estrutura de dados JSON anterior (contendo as variáveis de entrada), abre todos os ficheiro com os modelos gravados, converte num dicionário Python chamado “parametros”, aplica todos os modelos e passos do processo de machine learning de forma sequencial (em diferentes funções) como explicado anteriormente, estrutura as estimativas das variáveis num dicionário Python chamado “obj_final”, respondendo como parâmetros de saída o dicionário “obj_final” numa estrutura de dados JSON;

```
def modelos_corridos(arg):
    # carregar o modelo treinado de um arquivo
    with open('modelo.pkl1', 'rb') as f:
        modelo_salvo1 = pickle.load(f)

    with open('modelo.pkl', 'rb') as f:
        modelo_salvo = pickle.load(f)

    with open('modelo.pkl2', 'rb') as f:
        modelo_salvo2 = pickle.load(f)
```

Fig. 98 - Abertura dos ficheiros com os modelos de Machine Learning gravados

```
def machine_learning(arg):
    parametros = json.loads(arg)
```

Fig. 99 - Conversão dos parâmetros de entrada para um dicionário

```
##### n*A #####
def machine_learning(arg):
    parametros = json.loads(arg)

    ved = parametros["Ved"]
    df = pd.DataFrame({'Vz,Ed (kN)': [ved]})

    # fazer previsões com o modelo carregado
    previsoes = modelo_salvo1.predict(df)
    previsoes_arredondadas = float(np.ceil(previsoes)) # Arredonda as previsões
    dicionario_previsoes = {"A*d": float(np.ravel(previsoes_arredondadas)[0])}
    # imprimir as previsões
    print(previsoes)
    print("A*d :", previsoes_arredondadas)
    k = json.dumps(dicionario_previsoes)
    return k
```

Fig. 100 - Uma das funções para a estimativa de uma variável

```
obj_final = {**obj, **obj1, **obj2, **obj3, **obj4, **obj5, **obj6, **obj7, **obj8, **obj9,
              **obj10, **obj11, **obj12, **obj13, **obj14, **obj15, **obj16,
              **obj17, **obj18, **obj19, **obj20}

json_combined = json.dumps(obj_final)
print(json_combined)
return json_combined
```

Fig. 101 - Dicionário "obj_final" convertido para uma estrutura de dados JSON

- 5- Interface recebe a estrutura de dados JSON anterior (contendo as estimativas), converte num dicionário Python chamado “resultados_ML_dict” e apresenta em todas as caixas de entrada os valores;

Após este processo o procedimento do cálculo das verificações de segurança é o mesmo explicado anteriormente.

5.4. VALIDAÇÃO DA APLICAÇÃO

De forma a validar a ferramenta criada foram comparadas as características de 5 ligações metálicas projetadas pela empresa bysteel, desconhecidas à base de dados, e com parâmetros diferentes de entrada, de forma a garantir que não haja uma ligação igual ou muito similar na base de dados, em relação às características geradas pelos modelos de “Machine Learning” para essas ligações metálicas, resultando na seguinte Tabela

Tabela 11 - Comparação de resultados das características de ligações

Supporting beam***	Supported beam***	Vz,Ed (kN)	d	n1	n2	hp	tp	e1	e2	e1b	e2b	p1	p2
IPE500	IPE 360	139.70	20.00	3	2	260	10	50	50	100	50	80	80
IPE300	IPE550	177	16	4	2	400	10	50	40	120	40	100	80
IPE500	IPE 200	16	16	2	2	145	8	35	35	63	35	75	60
IPE500	IPE 160	34	16	2	2	120	10	25	30	45	40	70	60
IPE500	IPE 270	54	16	3	2	200	10	40	35	75	35	60	60
MACHINE LEARNING													
IPE500	IPE 360	139.70	20.00	3	2	270	15	45	40	90	40	90	70
IPE300	IPE550	177	24	3	2	390	15	45	45	125	45	150	70
IPE500	IPE 200	16	16	2	2	130	12	40	40	75	40	50	70
IPE500	IPE 160	34	20	2	2	110	15	25	30	50	30	60	70
IPE500	IPE 270	54	20	2	2	185	15	40	40	82.5	40	105	70

Pela comparação de valores, do ponto de vista macro, constata-se que os valores dimensionados por um projetista e a estimativa de valores estão bastante similares. Do ponto de vista micro verifica-se que os modelos de “Machine Learning” estimaram menos parafusos, mas com maior diâmetro em algumas ligações, que a espessura da chapa está um pouco sobredimensionada pelos modelos de “Machine Learning” em comparação aos valores do dimensionamento por um projetista e que a geometria dos parafusos dos furos se encontra similar.

6

CONSIDERAÇÕES FINAIS

6.1. CONCLUSÕES

Esta dissertação demonstra como o uso de ferramentas de inteligência artificial, em específico a utilização de “Machine Learning” auxilia bastante o processo de dimensionamento de uma ligação do tipo Fin-Plate. **Segundo a empresa bysteel “este processo de dimensionamento é realizado com uma demora à volta de 30 minutos por ligação, passou a ser possível ser realizado, com um nível de confiança atribuído, em apenas uns segundos”** a partir das previsões dos modelos de “Machine Learning” aplicados. Para além do enorme valor que esta ferramenta fornece ao dimensionamento e as métricas apresentadas para cada variável descoberta, a comparação dos valores dimensionados por um projetista ou pelos modelos de “Machine Learning” indicaram que esta ferramenta é uma boa ajuda no dimensionamento de ligações metálicas.

Este processo obteve alguns obstáculos, pois é raro um projeto de “Machine Learning” que envolva a previsão de tantas variáveis, sendo usual apenas a previsão de 1 ou 2 variáveis. Para além deste aspeto, o facto de cada variável prevista ter poucas variáveis características, ao longo do processo sequencial, também dificultou a obtenção de melhores previsões, sendo usual uma quantidade de variáveis características considerável para a previsão de uma outra.

Um aspeto importante que foi revelado ao longo desta dissertação é a importância, para a indústria, de armazenar dados e a forma de o fazer. Uma base de dados só é útil se for bem montada e se for para se retirar utilidade desta. O tamanho e a sua qualidade foram dois aspetos relevados importantes: o tamanho para a base de dados ser capaz de não sofrer tanto devido a erros, enviesamentos ou “outliers” que estejam contidos; e a qualidade pois uma base de dados que apresente erros não oferecerá conclusões com tanta qualidade, ou até mesmo conclusões enganosas. Neste projeto foi utilizada uma base de dados com apenas 126 linhas, que caso fosse aumentada e aplicada uma verificação de segurança para cada linha presente na base de dados garantíamos a sua qualidade e quantidade. Outro ponto importante seria o adicionar notas sobre cada ligação como: “número de parafusos condicionada pela extremidade oposta da viga”; “espessura da chapa condicionada pela produção em fábrica”; “disposição dos furos condicionados pela extremidade oposta da viga” e outras informações que fossem relevantes, pois estes aspetos são relevantes no dimensionamento de uma ligação metálica, mas que não foram tidos em conta para este projeto.

Um trabalho como o aplicado nesta dissertação envolve conhecimentos de engenharia civil, programação e trabalho com dados (“Data Science” e “Machine Learning”), envolvendo várias especialidades que não são todas abordadas na formação de um engenheiro civil. Este aspecto ajuda a refletir que cada vez mais se deve incluir na formação de base de um engenheiro civil estes conhecimentos, pois só assim o ramo de engenharia civil consegue acompanhar outras indústrias, realizando os trabalhos exigidos cada vez com melhor qualidade e maior rapidez.

6.1. DESENVOLVIMENTOS FUTUROS

As ferramentas de inteligência artificial vieram para ficar e terão certamente uma enorme evolução nos próximos anos. Todas as áreas da indústria poderão retirar proveito de uma análise de dados mais profunda podendo melhorar os seus processos.

Em relação à aplicação criada, ainda que os objetivos tenham sido cumpridos, é possível executar alguns passos de forma a melhorar desde a criação da base de dados inicialmente à forma como a aplicação está desenhada:

- Criação de uma base de dados robusta para este tipo de ligação composta por todas as componentes essenciais e adicionando as informações já acima abordadas. Adicionar ligações do tipo Fin-Plate com outros esforços aplicados (tração ou compressão) de forma a obter um dimensionador deste tipo de ligações transversal a todas as aplicações desta ligação;
- Utilização de outros modelos de “Machine Learning” de forma a testar se existirão melhores modelos a serem aplicados para a previsão de cada componente. A utilização de modelos de redes neurais é um possível caminho diferente a ser testado;
- Implementação de um processo de otimização acoplado à solução estimada pelos modelos de “Machine Learning” de forma a encontrar a solução mais otimizada para aquelas condicionantes impostas à priori. Os modelos, por se basearem em soluções não otimizadas, nunca seriam capazes de gerar uma solução otimizada, pelo que a adição de um processo de otimização, consoante a solução obtida pelo modelo de “Machine Learning”, iria testar diferentes possibilidades de ajustes que poderiam ser realizados consoante um conjunto de critérios a definir para otimização (custo, quantidade de ferro, menor quantidade de parafusos, menor espessura de chapa, etc);
- Um objetivo mais ambicioso seria, com as melhorias acima propostas, poder criar uma base de dados com todos os tipos de ligações existentes (salvo ligações especiais que necessitem de análise de elementos finitos) de forma a conseguir ter uma aplicação capaz de dimensionar qualquer ligação metálica independente da sua classificação;

Após ter concluído este trabalho constata-se as inúmeras vantagens existentes do uso de inteligência artificial, em concreto da ferramenta Machine Learning no auxílio de processos em engenharia. Espera-se que com a leitura deste documento seja possível expandir e demonstrar estas vantagens de forma a proporcionar novas investigações nesta área que é do presente e principalmente do futuro.

REFERÊNCIAS BIBLIOGRÁFICAS

- AÇO-DIM. (2020). *AÇO-DIM*. <https://aco-dim.com/aprender/tracao/Perfil-I-ligacao-parafusada-pela-mesa>
- BIC CONSTRUCTION ARCHITECTURAL JSC. (n.d.). *STEEL STRUCTURAL BOLT LINKS*. Retrieved June 15, 2023, from <https://bicjsc.com/link-en-332>
- European Design Recommendations for Simple Joints in Steel Structures*. (2006).
- Introdução ao JSON*. (n.d.). Retrieved June 10, 2023, from <https://www.json.org/json-pt.html>
- Jiang, K., Liang, Y., & Zhao, O. (2022). Machine-learning-based design of high strength steel bolted connections. *Thin-Walled Structures*, 179. <https://doi.org/10.1016/j.tws.2022.109575>
- Kuang, W. (2018a, October 23). *Steel Connection for Beams and Columns*. <https://skyciv.com/technical/steel-connection-design-for-beams-and-columns/>
- Kuang, W. (2018b, October 23). *Types of Steel Connections and their Classifications*. <https://skyciv.com/technical/types-of-steel-connections-and-their-classifications/>
- Mahmood Md. (2016). Classification System for Semi-Rigid Beam-to-Column Connections. *Latin American Journal of Solids and Structures*. <https://www.scielo.br/lajss/a/K9LzrG9FGkfRYHsgZH83cn/?format=pdf&lang=en>
- Málaga-Chuquitaype, C. (2022). Machine Learning in Structural Design: An Opinionated Review. In *Frontiers in Built Environment* (Vol. 8). Frontiers Media S.A. <https://doi.org/10.3389/fbuil.2022.815717>
- Malawi Medical Journal. (2012). *A guide to appropriate use of Correlation coefficient in medical research*. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3576830/>
- mec Engineering Spreadsheets. (2023). *mec Engineering Spreadsheets*. <https://www.mec-engineering-spreadsheets.com/categories/steel-connections/fin-plate-connection/>
- MechaniCalc. (2023). *Bolt Pattern Force Distribution*. <https://mechanicalc.com/reference/bolt-pattern-force-distribution>
- Norma Portuguesa. (1993a). *Eurocódigo 3-Projecto de estruturas de aço Parte 1-1: Regras gerais e regras para edifícios*. www.ipq.pt
- Norma Portuguesa. (1993b). *Eurocódigo 3-Projecto de estruturas de aço Parte 1-8: Projecto de ligações*. www.ipq.pt
- Oliveira Júnior, C. (2021, December 13). *Métricas para Regressão: Entendendo as métricas R^2 , MAE, MAPE, MSE e RMSE*. <https://medium.com/data-hackers/prevendo-n%C3%BAmoros-entendendo-m%C3%A9tricas-de-regress%C3%A3o-35545e011e70>

- scikit-learn developers. (2023a). *Decision Trees*. <https://scikit-learn.org/stable/modules/tree.html#minimal-cost-complexity-pruning>
- scikit-learn developers. (2023b). *LinearRegression*. https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LinearRegression.html
- scikit-learn developers. (2023c). *Nearest Neighbors*. <https://scikit-learn.org/stable/modules/neighbors.html>
- Shah, R. (2021, June 23). *Tune Hyperparameters with GridSearchCV*. <https://www.analyticsvidhya.com/blog/2021/06/tune-hyperparameters-with-gridsearchcv/>
- Smolic, H. (2022, December 15). *How Much Data Is Needed For Machine Learning?* . <https://graphite-note.com/how-much-data-is-needed-for-machine-learning#:~:text=Generally%20speaking%2C%20the%20rule%20of,100%20rows%20for%20optimal%20results.>
- Teixeira Araújo Peixoto, N. A. (2008). *Tese_Ligações_Aveiro*.
- The Steel Construction Institute. (2014a). *Joints in Steel Construction Simple Joints to Eurocode 3*. <http://shop.steelbiz.org>
- The Steel Construction Institute. (2014b). *SCI - Simple Joints to Eurocode 3*. <http://shop.steelbiz.org>
- Wikipedia. (2023a). *k-nearest neighbors algorithm*. https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm
- Wikipedia. (2023b, May 6). *Random forest*. https://en.wikipedia.org/wiki/Random_forest
- Wikipedia. (2023c, May 8). *Linear Regression*. https://en.wikipedia.org/wiki/Linear_regression
- Wikipedia. (2023d, May 30). *Decision tree learning*. https://en.wikipedia.org/wiki/Decision_tree_learning
- Zieliński Adam. (2008, May 13). *File:Polaczenie srubowe*. [https://commons.wikimedia.org/wiki/File:Polaczenie_srubowe_\(sruba_pasowana\).svg](https://commons.wikimedia.org/wiki/File:Polaczenie_srubowe_(sruba_pasowana).svg)