

Universidade do Minho
Escola de Engenharia

Aldo Flávio de Ribeiro Guimarães

**Utilização de técnicas *soft computing*
para identificação de propriedades
mecânicas de betão leve**

Dissertação de Mestrado
Mestrado Integrado em Engenharia Civil

Trabalho efetuado sob a orientação do
**Professor Doutor José António Silva de
Carvalho Campos e Matos**
e da
Professora Doutora Maria Isabel Brito Valente

Julho de 2013

DECLARAÇÃO

Nome: Aldo Flávio de Ribeiro Guimarães

Endereço eletrónico: aldoguimaraes_4625@hotmail.com

Telefone: 91 452 28 32

Título da dissertação: Utilização de técnicas *soft computing* para identificação de propriedades mecânicas de betão leve

Orientador(es): Professor Doutor José António Silva de Carvalho Campos e Matos e da Professora Doutora Maria Isabel Brito Valente

Ano de conclusão: 2013

Designação do Mestrado: Mestrado Integrado em Engenharia Civil

DE ACORDO COM A LEGISLAÇÃO EM VIGOR, NÃO É PERMITIDA A REPRODUÇÃO DE QUALQUER PARTE DESTE TRABALHO

Universidade do Minho, ____/ ____/ _____

Assinatura: _____

AGRADECIMENTOS

Ao meu orientador, Professor José António Silva de Carvalho Campos e Matos, pelos seus conselhos, disponibilidade e empenho ao longo desta dissertação.

À minha coorientadora, Professora Maria Isabel Brito Valente, pela atenção, disponibilidade e conhecimentos transmitidos.

À minha família, pelo apoio constante ao longo do meu percurso académico, em particular aos meus pais que possibilitaram e incentivaram a minha formação.

Aos meus colegas de curso, pelas experiências e conhecimentos partilhados ao longo deste percurso.

RESUMO

O betão leve é um material cuja utilização no campo da engenharia civil apresenta várias vantagens, como por exemplo, a sua baixa densidade, permitindo o desenvolvimento de estruturas mais esbeltas. Contudo, é ainda um material cujas propriedades apresentam um excessivo grau de incerteza. Este facto revela-se de maior importância para as construtoras quando pretendem produzir betão leve com determinadas características.

Fruto dessa necessidade este material tem vindo a ser profundamente estudado em diversas instituições tal como a Universidade do Minho. Nesse sentido diferentes ensaios mecânicos, químicos e de durabilidade foram desenvolvidos. Adicionalmente, as expressões dos atuais códigos modelo continuam a apresentar algum erro pois verifica-se que, e ao contrário do betão normal, as propriedades reais se afastam das previstas.

Com a presente dissertação pretende-se aprofundar o estudo do material betão leve e das atuais leis, presentes no Eurocódigo, que servem para estimação dos seus parâmetros. Nesse sentido, e com base num vasto conjunto de ensaios realizados pela Universidade do Minho, são aplicadas técnicas *soft computing* para avaliação dos parâmetros mecânicos que, derivam desse conjunto de ensaios.

As técnicas *soft computing* aplicadas são as Redes Neurais Artificiais, Árvores de Regressão e k-Vizinhos Mais Próximos. Com base nestas técnicas *soft computing* é efetuado o desenvolvimento de modelos de previsão que permitem estimar as propriedades do betão leve de acordo com a quantidade dos seus componentes iniciais. Comparam-se os modelos desenvolvidos pelas diferentes técnicas *soft computing* e, através da avaliação do desempenho de cada um, é identificado o melhor. Posteriormente, com base na informação de misturas de referência, é realizada uma análise aos parâmetros estimados pelas leis presentes no Eurocódigo e pelo melhor modelo.

Palavras-Chave: betão leve, *soft computing*, redes neuronais artificiais, árvores de regressão, k-vizinhos mais próximos.

ABSTRACT

Lightweight concrete is a material often used in civil engineering. It presents a lower density than normal weight concrete, which allows the development of slender structures. However, its properties have an excessive level of uncertainty. This is important to constructors when they want to produce lightweight concrete with specific characteristics.

This dissertation intends to study lightweight concrete and the laws presented in the Eurocode to estimate its mechanical properties. The expressions recommended in the current model codes continue to present some error, because unlike normal weight concrete, the actual properties of lightweight concrete deviate from the predicted ones.

This material has been studied in several institutions, such as University of Minho. Accordingly, various mechanical, chemical and durability tests were developed. Based on a set of experimental tests carried out at the University of Minho, soft computing techniques are applied to analyze the mechanical parameters of lightweight concrete.

The applied soft computing techniques include artificial neural networks, regression trees and k-nearest neighbors. Based on these techniques, predictive models of lightweight concrete properties, according to different amounts of its components, will be developed. A comparison between the models developed by the different soft computing techniques is made, with the objective of identifying the best model. The best model is identified through the assessment of each developed model. Subsequently, based on the information provided by the reference mixtures, an analysis is made based on the parameters estimated by laws presented in the Eurocode and, by the model previously identified as the best.

Keywords: lightweight concrete, soft computing, artificial neural networks, regression trees, k-nearest neighbors.

ÍNDICE

ÍNDICE DE FIGURAS	xi
ÍNDICE DE QUADROS	xv
1 INTRODUÇÃO	1
1.1 Introdução e motivação	1
1.2 Objetivos.....	2
1.3 Estrutura da dissertação.....	3
2 REVISÃO DO ESTADO DA ARTE	5
2.1 Betão leve	5
2.1.1 Introdução.....	5
2.1.2 Definição	5
2.1.3 Fatores económicos.....	6
2.1.4 Componentes da mistura	7
2.1.5 Propriedades mecânicas	10
2.2 <i>Soft computing</i>	13
2.2.1 Introdução.....	13
2.2.2 Fase de treino.....	13
2.2.3 Cuidados quanto às técnicas <i>soft computing</i>	14
3 METODOLOGIA DA INVESTIGAÇÃO	15
3.1 Técnicas <i>soft computing</i> utilizadas	15
3.1.1 Redes neuronais artificiais.....	15
3.1.2 k-Vizinhos mais próximos.....	19
3.1.3 Árvores de regressão	20
3.2 Avaliação dos modelos.....	21
3.3 Análise da base de dados.....	22
4 RESULTADOS OBTIDOS	25
4.1 Densidade	25
4.2 Resistência à compressão	28
4.2.1 Resistência à compressão de provetes cúbicos.....	28
4.2.2 Resistência à compressão de provetes cilíndricos	31
4.3 Módulo de elasticidade.....	38
4.4 Resistência à tração	45

5	CONCLUSÕES.....	51
6	REFERÊNCIAS BIBLIOGRÁFICAS	53
	ANEXOS	55
	A.1	55
	A.2	57
	A.3	59
	A.4	62
	A.5	64
	A.6	67

ÍNDICE DE FIGURAS

Capítulo 3 - Metodologia da investigação

Figura 1 - Perceptrão multicamada	16
Figura 2 - Modelo de um neurónio artificial	16
Figura 3 - k-Vizinhos mais próximos aplicado à classificação	19
Figura 4 - Árvore de regressão	20

Capítulo 4 - Resultados obtidos

Figura 5 - Mistura B16, erro relativo vs. tempo para cada modelo	26
Figura 6 - Mistura B16, densidade estimada vs. densidade medida para rede neuronal artificial	26
Figura 7 - Esquema da árvore de regressão.....	30
Figura 8 - Mistura B15, erro relativo vs. Tempo	32
Figura 9 - Rede neuronal artificial, comparação entre a resistência à compressão de provetes cilíndricos estimada e medida.....	32
Figura 10 - k-Vizinhos mais próximos, comparação entre a resistência à compressão de provetes cilíndricos estimada e medida.....	33
Figura 11 - Árvore de regressão, comparação entre a resistência à compressão de provetes cilíndricos estimada e medida.....	33
Figura 12 - Número de registos de resistência à compressão de provetes cilíndricos conforme o instante de tempo.....	34
Figura 13 - Erro relativo conforme o número de registos	35
Figura 14 - Mistura B15, erro relativo vs. tempo	36
Figura 15 - Mistura B15, comparação entre os valores estimados pela equação (4.2) e os valores medidos	37
Figura 16 - Erro relativo vs. tempo	39
Figura 17 - Rede neuronal artificial, comparação entre os módulos de elasticidade estimado e medido	40
Figura 18 - Árvore de regressão, comparação entre os módulos de elasticidade estimado e medido	40
Figura 19 - Número de registos de módulo de elasticidade conforme o instante de tempo....	42
Figura 20 - Erro relativo conforme o número de registos	42

Figura 21 - Mistura B16, erro relativo vs. tempo para a rede neuronal artificial e para o modelo do Eurocódigo	44
Figura 22 - Mistura B16, comparação entre os valores estimados pelo modelo do Eurocódigo e os valores medidos	44
Figura 23 - Mistura B16, comparação entre os valores estimados pela rede neuronal artificial e os valores medidos	45
Figura 24 - Erro relativo vs. tempo	46
Figura 25 - Relação entre os valores estimados e medidos para rede neuronal artificial	47
Figura 26 - Relação entre valores estimados e medidos para k-vizinhos mais próximos.....	47
Figura 27 - Comparação entre os valores estimados e medidos para a rede neuronal artificial	49
Figura 28 - Comparação entre os valores estimados e medidos para o modelo do Eurocódigo	50

Anexos

Figura 29 - Número de registos de densidade conforme o instante de tempo.....	55
Figura 30 - Número de registos de resistência à compressão de provetes cúbicos conforme o instante de tempo	55
Figura 31 - Número de registos de resistência à compressão de provetes cilíndricos conforme o instante de tempo.....	56
Figura 32 - Número de registos de módulo de elasticidade conforme o instante de tempo....	56
Figura 33 - Número de registos de resistência à tração conforme o instante de tempo	56
Figura 34 - Mistura B16, erro relativo vs. tempo para os diferentes modelos de redes neuronais artificiais	57
Figura 35 - Mistura B16, série referente aos erros relativos ao longo do tempo.....	58
Figura 36 - Mistura B4, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais	60
Figura 37 - Mistura B8, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais	60
Figura 38 - Mistura B15, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais	63
Figura 39 - Mistura B16, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais	65
Figura 40 - Mistura B16, erro relativo ao longo do tempo para as diferentes redes neuronais artificiais	65

Figura 41 - Mistura B15, erro relativo conforme o instante para as diferentes redes neuronais artificiais	67
Figura 42 - Mistura B15, erro relativo conforme o instante de tempo para os modelos de redes neuronais artificiais desenvolvidos	68

ÍNDICE DE QUADROS

Capítulo 2 - Revisão do estado da arte

Quadro 1 - Classes de betões leves	5
--	---

Capítulo 4 - Resultados obtidos

Quadro 2 - Misturas de referência B16 e B42	25
Quadro 3 - Densidade estimada	27
Quadro 4 – Erro associado à densidade estimada	27
Quadro 5 - Média do erro para as misturas em causa	28
Quadro 6 – Misturas de referência B2, B4 e B8	29
Quadro 7 – Erro associado ao valor estimado da resistência à compressão de provetes cúbicos	29
Quadro 8 – Valor estimado da resistência à compressão de provetes cúbicos	30
Quadro 9 – Constituição das misturas de referência B15 e B16	31
Quadro 10 – Erro associado ao valor estimado de resistência à compressão de provetes cilíndricos	34
Quadro 11 – Erro associado ao valor estimado da resistência à compressão de provetes cilíndricos	36
Quadro 12 – Misturas de referência B16 e B42	38
Quadro 13 – Valor estimado do módulo de elasticidade	39
Quadro 14 – Erro associado aos valores de módulo de elasticidade estimado	41
Quadro 15 – Módulo de elasticidade estimado pelos diferentes modelos	41
Quadro 16 – Erro associado aos valores de módulo de elasticidade estimados pela rede neuronal artificial e pelo Eurocódigo	43
Quadro 17 – Mistura de referência B15	46
Quadro 18 – Resistência à tração estimada	47
Quadro 19 – Erro associado aos valores de resistência à tração estimados	48
Quadro 20 – Erro associado aos valores de resistência à tração estimados pela rede neuronal artificial e pelo Eurocódigo	49

Anexos

Quadro 21 - Erro quadrático para os diferentes modelos de redes neuronais artificiais	57
---	----

Quadro 22 – Valor do erro conforme o valor de k.....	58
Quadro 23 – Erro médio obtido por validação cruzada para diferentes números de observações por folha.....	59
Quadro 24 – Erro quadrático para os diferentes modelos de redes neuronais artificiais	60
Quadro 25 – Valor do erro conforme o valor de k.....	61
Quadro 26 - Erro médio Obtido por validação cruzada para diferentes números de observações por folha.....	62
Quadro 27 – Erro quadrático para os diferentes modelos de redes neuronais artificiais	62
Quadro 28 – Valor do erro conforme o valor de k.....	63
Quadro 29 - Erro médio obtido por validação cruzada para diferentes números de observações por folha.....	64
Quadro 30 – Erro quadrático para os diferentes modelos de redes neuronais artificiais	64
Quadro 31 – Valor do erro conforme o valor de k.....	66
Quadro 32 – Erro médio obtido por validação cruzada para diferentes números de observações por folha.....	66
Quadro 33 – Erro quadrático para as diferentes redes neuronais artificiais	67
Quadro 34 – Erro médio obtido por validação cruzada para cada valor de k.....	69
Quadro 35 - Erro médio obtido por validação cruzada para diferentes números de observações por folha.....	69

1 INTRODUÇÃO

1.1 Introdução e motivação

O betão leve é um material relevante e versátil na construção moderna. Tem muitas e variadas aplicações, incluindo, edifícios de grande altura, pontes, plataformas petrolíferas e elementos pré-esforçados ou pré-fabricados de vários tipos. Muitos arquitetos e engenheiros reconhecem as vantagens oferecidas por este material, como se evidencia pelas várias estruturas executadas com betão leve, que é possível encontrar por todo o Mundo.

Apesar do betão leve não ser um material novo, a sua conceção e uso não é tão bem aceite como no caso do betão normal. Isto verifica-se, apesar das diversas aplicações nas quais o betão leve oferece vantagens técnicas sobre o betão normal. Os principais motivos que dificultam a sua aceitação são o seu maior custo, a falta de confiança nas suas propriedades e a ausência de normas que sejam aceites de uma forma generalizada (BE 96-3942/R27, 2000).

As expressões dos atuais códigos modelo apesar de validadas, continuam a apresentar algum erro pois verifica-se que, e ao contrário do betão normal, as propriedades reais se afastam das previstas. O grau de incerteza quanto às propriedades do betão leve revela-se de maior importância, por exemplo, quando as construtoras pretendem produzir betão leve com determinadas características.

Assim, tem sido desenvolvido um vasto trabalho experimental por diversas instituições, como a Universidade do Minho, com o objetivo de determinar e documentar as propriedades do betão leve. A necessidade de normas que ofereçam, com maior detalhe, orientações para seleccionar os materiais que constituem a mistura de betão e, em alguns casos, designem requisitos adicionais a cumprir, requer este tipo de trabalho (BE 96-3942/R14, 2009). Nesse sentido, foram desenvolvidos na Universidade do Minho diferentes ensaios mecânicos, químicos e de durabilidade.

Neste contexto, pretende-se com esta dissertação aprofundar o estudo do material em causa. Com base na relação existente entre os componentes da mistura de betão leve e as suas propriedades mecânicas, pretende-se aplicar técnicas *soft computing* para, através das

diferentes proporções de uma dada mistura se estimar as propriedades mecânicas do betão leve ao longo do tempo. Efetuando uma análise inversa, as empresas produtoras de betão leve poderão definir de um modo rápido as proporções dos constituintes da mistura, de acordo com as propriedades mecânicas que pretendem para o betão leve.

Nas últimas décadas, novas ferramentas nas áreas da informática e estatística têm sido desenvolvidas. A mineração de dados é uma área da informática que combina diferentes técnicas computacionais, designadas de técnicas *soft computing*, para providenciar maior conhecimento acerca dos dados presentes numa base de dados. O enorme volume de uma base de dados, a complexidade da informação que esta armazena, bem como as limitações humanas associadas, condicionam a extração de conhecimento. Por isso, de forma a ultrapassar estas limitações, é necessária a aplicação de ferramentas automáticas, ou seja, de técnicas *soft computing* que permitam a análise e extração de informação de dados em bruto.

A mineração de dados incorpora as técnicas *soft computing* que têm como modelo a mente humana e tentam formalizar o processo cognitivo humano. As técnicas *soft computing* permitem extrair, a partir de informações imprecisas, vagas e com elevado grau de incerteza, soluções consideradas robustas, processáveis e de baixo custo (Shukla, Tiwari, & Kala, 2010).

1.2 Objetivos

O principal objetivo desta dissertação é aplicar técnicas *soft computing* para estabelecer modelos que permitam estimar as propriedades mecânicas de betão leve ao longo do tempo com base nos constituintes de uma dada mistura. Para isso, as técnicas *soft computing* incidirão numa base de dados constituída por resultados de ensaios mecânicos realizados pela Universidade do Minho. Um dos objetivos consiste em aprofundar o conhecimento do material betão leve e, das leis de estimação dos parâmetros mecânicos deste material, presentes no Eurocódigo.

1.3 Estrutura da dissertação

Esta dissertação começa com o presente capítulo, onde é feita uma introdução, indicada a motivação e estabelecidos os objetivos. É também apresentada uma breve descrição do conteúdo de cada capítulo.

A primeira parte deste trabalho, nomeadamente o Capítulo 2, é dedicada aos fundamentos teóricos afetos ao tema. Define-se o betão leve e são apresentadas as suas características, os seus constituintes e parâmetros mecânicos. É também abordada a mineração de dados, na qual se inserem as técnicas *soft computing*, através da apresentação de noções relativas ao desenvolvimento de modelos e cuidados relativos à utilização destas técnicas.

A explanação da metodologia adotada no desenvolvimento dos modelos de previsão é efetuada no Capítulo 3. Em conjunto com a descrição dos aspetos gerais que definem os modelos é apresentada uma descrição do seu funcionamento. É efetuada a análise da base de dados utilizada e abordado o procedimento referente à avaliação do seu desempenho.

No Capítulo 4 é realizada a avaliação dos modelos desenvolvidos e a consequente identificação do modelo de melhor desempenho. Conforme o parâmetro mecânico em análise, é ainda efetuada uma comparação entre o modelo identificado com melhor desempenho e a respetiva lei segundo o Eurocódigo.

As conclusões gerais deste trabalho e, aspetos afetos ao seu futuro desenvolvimento são apresentados no Capítulo 5.

2 REVISÃO DO ESTADO DA ARTE

2.1 Betão leve

2.1.1 Introdução

O betão leve é conhecido desde os tempos do Império Romano. De facto, tanto o Coliseu (Roma, Itália, 80 A.D.) como o Panteão (Roma, Itália, 123 A.D.) foram parcialmente construídos com materiais que podem ser caracterizados como constituintes de betão leve (ex. pedra-pomes, escória, etc.) (Chandra & Berntsson, 2002).

A menor densidade, e a maior capacidade de isolamento térmico, são as características mais importantes que distinguem o betão leve do betão de densidade normal (BE 96-3942/R2, 1998). Contudo, estas não são as únicas características que definem o betão leve. Caso assim fosse, a maioria das normas relativas à mistura, execução, dimensionamento estrutural, etc., aplicáveis ao betão normal, aplicar-se-iam também ao betão leve. De fato, o betão leve apresenta algumas diferenças em relação ao betão normal que contemplam a mistura, a execução, a permeabilidade, as propriedades mecânicas, etc. (Harmon).

2.1.2 Definição

O betão leve é definido como sendo um material produzido com base numa utilização parcial ou total de agregados leves, e cuja massa volúmica após secagem em estufa deve se encontrar entre os 800kg/m^3 e os 2000 kg/m^3 (NP EN 206-1, 2007). Segundo a NP EN 206-1 (2007), apresenta-se no Quadro 1 a classificação do betão leve de acordo com a sua massa volúmica.

Quadro 1 - Classes de betões leves

Classe de massa volúmica	D1,0	D1,2	D1,4	D1,6	D1,8	D2,0
Massa volúmica (kg/m^3)	≥ 800 e ≤ 1000	> 1000 e ≤ 1200	> 1200 e ≤ 1400	> 1400 e ≤ 1600	> 1600 e ≤ 1800	> 1800 e ≤ 2000

A principal distinção entre betões leves e betões normais é a menor massa volúmica que os agregados leves apresentam. O agregado leve é um agregado de origem mineral com massa volúmica após secagem em estufa menor ou igual a 2000 kg/m^3 , quando determinada de acordo com a NP EN 1097-6, ou com uma baridade após secagem em estufa menor ou igual a 1200 kg/m^3 , quando determinada segundo a NP EN 1097-3 (NP EN 206-1, 2007).

Os agregados leves constituem grande parte da mistura de betão leve tendo por isso, as suas propriedades, uma influência significativa nas propriedades do betão leve (Harmon). De entre as várias características do betão leve, são de realçar, a sua capacidade como isolante térmico e a sua durabilidade.

2.1.3 Fatores económicos

O uso de betão leve numa estrutura resulta usualmente num menor custo global. Apesar de o betão leve apresentar um custo superior ao do betão normal por metro cúbico, a estrutura poderá custar menos devido ao seu menor peso próprio (ACI Committee 213, 1999). Alguns exemplos das vantagens económicas da utilização do betão leve são:

- A redução das cargas transmitidas às fundações (devido ao menor peso próprio do betão leve) pode resultar em sapatas de menor dimensão, na necessidade de um menor número estacas, e na redução da quantidade de aço utilizada;
- O menor valor da ação permanente pode fazer com que os elementos de suporte da estrutura (pilares, vigas, lajes, etc.) tenham secção transversal de menor dimensão;
- Em elementos de betão pré-esforçados, o menor valor da ação permanente pode resultar numa substancial redução da força de pré-esforço a aplicar.

Outra das vantagens resultante da redução do peso próprio do betão é a maior resistência dos elementos da estrutura a ações sísmicas, uma vez que, regra geral, estas são proporcionais ao seu peso próprio (Mehta & Monteiro, 2006). No entanto, deve ser referido que as principais aplicações de betão leve continuam a ser na produção de elementos de betão pré-fabricados. Devido ao manuseamento, transporte, e custos de construção, a utilização do betão leve adequa-se á pré-fabricação.

2.1.4 Componentes da mistura

Os agregados leves são menos resistentes do que os agregados normais e, de forma a compensar a sua menor resistência, é usada uma maior quantidade de cimento na mistura, mantendo-se a razão água-cimento baixa através da aplicação de adjuvantes (Clark, 1993). Contudo, a maior quantidade de cimento utilizada, por si só, não permite obter os níveis de resistência desejados. Neste sentido, é preciso lembrar as vantagens que as características dos agregados leves conferem à amassadura. Estas são, a capacidade de adesão do agregado leve à pasta de cimento e a proximidade entre os seus coeficientes de expansão térmica que conduzem à obtenção de um betão coerente com poucas ou nenhuma microfissuras (Chandra & Berntsson, 2002). A água absorvida também ajuda ao prolongamento da hidratação.

Outras vantagens da compatibilidade entre o agregado leve e a pasta de cimento são a redução da permeabilidade e a reduzida tendência para a abertura de fissuras no betão devidas à retração (Chandra & Berntsson, 2002). Em seguida, procede-se a uma descrição sucinta dos vários componentes de uma amassadura, bem como, à indicação das referências normativas às quais estes devem obedecer.

2.1.4.1 Agregados leves

As propriedades do betão leve estão relacionadas com as propriedades dos agregados utilizados na sua produção. As propriedades dos agregados leves dependem, por sua vez, da matéria-prima e do processo através do qual são produzidos (BE 96-3942/R2, 1998). As propriedades elásticas, resistência à compressão, durabilidade, resistência ao fogo, entre outras propriedades do betão, são dependentes do tipo de agregado leve utilizado na mistura (Harmon).

Os agregados leves podem ser produzidos a partir de materiais naturais de origem vulcânica, como a pedra-pomes e os tufos, ou por tratamento mecânico. Os agregados leves podem também ser artificiais, produzidos por tratamento térmico, através de matérias-primas como a argila, resíduos industriais, entre outros materiais (Chandra & Berntsson, 2002). No que concerne aos requisitos dos agregados leves, estes devem cumprir a NP EN 13055-1. As superfícies das partículas do agregado são constituídas por poros que variam em tamanho e, como tal, a absorção de água e a taxa de absorção podem variar significativamente (BE 96-

3942/R2, 1998). Assim, a quantidade de água necessária para produzir um betão de determinada consistência varia significativamente com as características do agregado leve. Esta variação relativa à quantidade de água requerida pela amassadura reflete-se, da mesma forma na quantidade de cimento necessária para produzir um betão com uma dada resistência (Clark, 1993).

A resistência intrínseca às partículas de agregado leve, principalmente as mais grossas, tem também um efeito importante na quantidade de cimento necessária, particularmente para betões de elevada resistência (Harmon). As proporções relativas aos constituintes da amassadura que geralmente os produtores de agregados leves fornecem providenciam recomendações quanto à quantidade de cimento e outras proporções que devem ser usadas como referência para a realização dos ensaios (Clark, 1993).

2.1.4.2 Agregado fino

Qualquer agregado de massa volúmica normal (agregado normal) utilizado no fabrico de betão leve deve cumprir as disposições da NP EN 12620. Na maioria dos casos a combinação de agregados leves com agregados normais é usada na produção de betão leve. Os fatores que influenciam a proporção entre os agregados normais e os agregados leves são a densidade e resistência requeridas para o betão, bem como, a qualidade e a graduação do agregado leve. Frequentemente, os agregados leves finos, estão apenas disponíveis através do esmagamento dos agregados leves mais grossos. Nestes casos a necessidade de água aumenta, e as características de trabalhabilidade do betão são prejudicadas (BE 96-3942/R2, 1998). Portanto, um dimensionamento ótimo da amassadura é normalmente alcançado através da combinação dos agregados leves grossos com a areia natural.

Os requisitos de utilização de areia natural na produção de betão leve serão iguais aos necessários para a produção de betão normal. A dimensão máxima das partículas de areia natural deverá corresponder à dimensão mínima do agregado leve. A quantidade ótima de areia natural, tal como para o betão normal, ajusta-se à quantidade de pasta de cimento. Isto é, para amassaduras ricas em cimento é desejável uma baixa quantidade de areia natural e vice-versa (BE 96-3942/R2, 1998).

2.1.4.3 Cimento

O cimento de Portland é o ligante com maior utilização na construção, principalmente por fatores relacionados com o seu desempenho e economia. Os conhecimentos sobre as matérias-primas, processo produtivo, processo de hidratação, etc., bem como dos diferentes tipos e classes de cimento e as suas características, influenciam a escolha do ligante a utilizar.

O cimento deverá atender os requisitos estabelecidos na EN 197-1. Hoje em dia, no que concerne aos requisitos de durabilidade, há uma tendência de dar mais enfoque à relação efetiva água/ligante (BE 96-3942/R2, 1998). Contudo, no que concerne à qualidade e quantidade de cimento, devem ser asseguradas características como a boa resistência contra a corrosão e a boa trabalhabilidade.

2.1.4.4 Adjuvantes

Os adjuvantes são constituintes essenciais do betão quando se pretende modificar as suas propriedades tanto no estado fresco como no estado endurecido. Estes são normalmente utilizados em dosagens baixas tendo como finalidade provocar alterações específicas tais como: melhorar a trabalhabilidade, reduzir a quantidade total de água usada na mistura, acelerar ou retardar a presa, acelerar ou retardar o endurecimento, etc. O adjuvante a adicionar durante o processo de mistura do betão deve estar de acordo com as especificações da NP EN 934-2.

2.1.4.5 Água

A água de amassadura tem como funções, hidratar o ligante, molhar os agregados, permitir a realização da mistura e facilitar a colocação em obra. A água deverá ser quimicamente apropriada, isto é, deve-se assegurar que esta não possui características prejudiciais ao desenvolvimento da hidratação. Os requisitos relativos à água utilizada na produção de betão encontram-se na NP EN 1008.

2.1.5 Propriedades mecânicas

A performance mecânica do betão leve difere do betão convencional. Isto verifica-se devido à substituição dos agregados naturais, usualmente utilizados, por agregados leves (BE 96-3942/R2, 1998). As seguintes propriedades mecânicas que serão aqui analisadas são:

- Resistência à compressão (f_{ic});
- Módulo de elasticidade (E_{ic});
- Resistência à tração (f_{it});
- Relação entre a resistência à compressão (f_{ic}) e densidade (ρ);
- Relação entre o módulo de elasticidade (E_{ic}) e resistência à compressão (f_{ic});
- Relação entre a resistência à tração (f_{it}) e resistência à compressão (f_{ic}).

2.1.5.1 Resistência à compressão (f_{ic})

A resistência à compressão dos betões em geral é afetada por um vasto conjunto de fatores. Os principais são: natureza e dosagem do ligante, características do agregado (granulometria, máxima dimensão, forma, textura superficial, resistência, rigidez, etc.), relação água-ligante, idade, grau de compactação, condições de cura, relação ligante-agregados (Neville, 1994).

É frequente substituir a fração de agregados leves finos por areia natural. Esta, sendo mais densa, aumenta a massa volúmica da mistura. Por outro lado, a utilização da areia natural permite uma diminuição da quantidade de água de amassadura, o que possibilita um aumento da resistência do betão.

O bom vínculo agregados-ligante, e a similaridade entre a rigidez do agregado e da matriz de argamassa, resultam numa amassadura mais homogénea com conseqüente melhoria do comportamento mecânico do betão (Chandra & Berntsson, 2002). Relativamente à regulamentação, a NP EN 206 considera classes de resistência à compressão que vão desde a LC8/9 à LC80/88 em que a resistência característica à compressão medida em cilindros varia, respetivamente, entre 8 MPa e 80 MPa.

As equações apresentadas pela NP EN 1992-1-1, depois dos 28 dias de idade, são capazes de prever a evolução da resistência à compressão do betão leve, embora se observe ao longo do

tempo uma taxa de crescimento da resistência superior à que se verifica na prática (Valente, 2007).

2.1.5.2 Módulo de elasticidade (E_{lc})

A rigidez de um betão depende da rigidez dos seus constituintes e da relação entre as suas proporções volumétricas na mistura. Uma vez que o módulo dos agregados leves é geralmente inferior ao dos agregados normais, e também devido ao facto de normalmente o betão leve possuir uma quantidade de ligante superior à do betão normal, o módulo de elasticidade do betão leve é inferior ao do betão normal (ACI Committee 213, 1999).

Considerando de forma simplificada o betão como sendo constituído por agregados leves embebidos numa argamassa, o módulo de deformabilidade do betão decresce caso se verifique: um decréscimo da rigidez da argamassa (cuja rigidez depende da razão água-ligante); um decréscimo da rigidez dos agregados (Clark, 1993).

Quando os elementos estruturais estão sujeitos a determinada ação, o baixo valor do módulo de elasticidade do betão leve dá origem a deformações maiores. Contudo, o efeito é reduzido pelo menor peso próprio dos elementos, executados em betão leve. A menor rigidez do betão leve pode ser benéfica, por exemplo, no caso dos elementos estruturais serem solicitados por ações dinâmicas, tais como sismos (Clark, 1993).

A aplicação das equações apresentadas na NP EN 1992-1-1 ao betão leve tem, como resultado, um valor do módulo de elasticidade superior ao que se verifica na prática (Valente, 2007). Ensaios experimentais revelaram que para ambas as equações nos primeiros dias de idade do betão (3 e 7 dias) a taxa de crescimento do valor do módulo de elasticidade que estas indicam é inferior à que se verifica na prática (Valente, 2007).

2.1.5.3 Resistência à tração (f_{lt})

A resistência à tração de um betão é importante quando se considera o comportamento em serviço das estruturas de betão armado. Efetivamente, a resistência à tração é preponderante no tratamento dos estados limites de fendilhação tendo, como tal, uma implicação direta na durabilidade das estruturas.

Os betões leves apresentam valores de resistência à tração ligeiramente inferiores aos betões de massa volúmica normal, para o mesmo nível de resistência à compressão (Kockal & Ozturan, 2010). A resistência à tração dos betões leves é influenciada pela resistência à tração dos agregados, da argamassa e da aderência entre estes componentes.

Resultados de ensaios experimentais demonstraram que, os valores de resistência à tração obtidos pelas equações da NP EN 1992-1-1 são significativamente superiores aos reais (Valente, 2007). Os resultados indicaram também que a taxa de crescimento da resistência à tração tende, ao longo do tempo, a ser superior à real.

2.1.5.4 Relação entre a resistência à compressão (f_{lc}) e densidade (ρ)

Em geral, a resistência à compressão do betão leve tende a aumentar com o aumento da densidade do agregado (Clark, 1993). Contudo, não há uma relação direta entre a densidade e a resistência à compressão (Kockal & Ozturan, 2010). Sabe-se, porém, que quanto maior for o tamanho das partículas de agregado leve menor é a sua densidade e menor é a resistência do agregado.

2.1.5.5 Relação entre o módulo de elasticidade (E_{lc}) e resistência à compressão (f_{lc})

Resultados de estudos experimentais demonstram que a relação entre estes dois parâmetros é praticamente linear (Valente, 2007).

2.1.5.6 Relação entre a resistência à tração (f_{lt}) e resistência à compressão (f_{lc})

De acordo com Curcio et al (1998), a resistência à tração corresponde a 6-6.5% da resistência à compressão medida em cilindros.

2.2 *Soft computing*

2.2.1 Introdução

A mineração de dados diz respeito a uma das etapas do processo *Knowledge Discovery in Databases* que permite obter conhecimento a partir de bases de dados. O processo pode ser resumido em cinco etapas, nomeadamente: pré-processamento, transformação, mineração de dados e interpretação (Fayyad, Piatetsky-Shapiro, & Smyth, 1996).

A mineração de dados concerne a aplicação de algoritmos adequados à extração de conhecimento a partir de dados em bruto, e incorpora as técnicas *soft computing*. Por isso, a mineração de dados é uma área da informática referente à estatística, à gestão de bases de dados, à inteligência artificial, entre outras.

A aplicação de técnicas *soft computing* visa encontrar padrões e relações entre variáveis com o objetivo de prever o seu estado futuro. Algumas das técnicas utilizadas são: os sistemas *fuzzy*, as redes neuronais artificiais, árvores de decisão, etc.

Em problemas de previsão de valores, os valores de saída (aqueles que se pretendem prever) são desconhecidos e determinados em função dos valores de entrada. Neste sentido, pretende-se que o modelo preveja os valores de saída em função de determinados valores de entrada. Essa capacidade é desenvolvida durante uma fase designada de “fase de treino”. Sempre que um valor de entrada é fornecido, o modelo determina o valor de saída. É muito difícil obter para qualquer valor de entrada o valor de saída com um alto grau de precisão. Contudo, o valor de saída previsto pelo modelo é geralmente muito próximo do correto. A proximidade obtida dependerá do valor de entrada e do tipo de treino que o modelo desenvolvido foi capaz de executar.

2.2.2 Fase de treino

A fase de treino decorre com base num conjunto de dados referente ao problema que se pretende resolver. Durante a fase de treino o modelo tenta através do conjunto de dados apresentado “aprender” a informação que o conjunto contém.

Quanto maior for o volume de dados apresentado melhor é o centro de interesse para a fase de treino. Os dados contêm informação, regras e inferências que, sem a utilização de técnicas *soft computing* seriam difíceis de encontrar.

O emprego de técnicas *soft computing* visa descobrir a informação, regras e inferências presentes num determinado conjunto de dados de modo a que quando os mesmos, ou dados idênticos, forem apresentados o modelo possibilite a resposta correta.

De acordo com o mencionado é vital uma boa base de dados para a fase treino. O princípio subjacente a um modelo é que valores de saída podem sempre ser reproduzidos em função de valores de entrada. Assim, para que o modelo efetue a previsão de valores de saída o mais corretamente possível, é importante a obtenção de uma base de dados adequada ao problema. Em certa medida, o desempenho do modelo depende do volume da base de dados. A base de dados deve ser suficientemente grande, caso contrário o modelo efetuará previsões erradas que podem parecer corretas ao utilizador. Para além disso, a validação do modelo deve ter em consideração um grupo considerável de valores de entrada, de modo a que o seu desempenho não seja drasticamente afetado perante qualquer valor de entrada futuro.

2.2.3 Cuidados quanto às técnicas *soft computing*

Todos os modelos têm uma suscetibilidade associada. Isto é mais óbvio quando o modelo falha. Não é possível assegurar que qualquer modelo continue a desempenhar as suas funções de forma contínua sem a existência de falhas ou erros, uma vez que estes são parte constituinte de todos os modelos. Deste modo, é possível um modelo gerar respostas erradas ou até sucumbir. O caso das técnicas *soft computing* é ainda mais especial.

Mesmo após um longo período de pesquisa, não é ainda possível obter um modelo cem por cento fiável. Isto significa que os modelos obtidos através de técnicas *soft computing* não são para serem usados desmesuradamente. Todos os modelos obtidos por técnicas *soft computing* têm um pequeno erro associado que deve ser considerado. Normalmente, tal erro é aceitável para o utilizador ou para a aplicação, e portanto não é tão importante. Mas em determinadas condições, este erro pode verificar-se crítico.

3 METODOLOGIA DA INVESTIGAÇÃO

3.1 Técnicas *soft computing* utilizadas

As técnicas *soft computing* utilizadas neste trabalho foram as Redes Neurais Artificiais pela sua potencialidade, k-Vizinhos Mais Próximos e Árvores de Regressão pela sua simplicidade e método de funcionamento distinto. Uma breve explicação destes algoritmos é apresentada nos subcapítulos seguintes.

O *software* de modelação utilizado foi o MATLAB[®] (R2012b 8.0) que é um software comercial de computação numérica e gráfica. Dentro do ambiente MATLAB foram usadas duas ferramentas específicas, a *Neural Network Toolbox* e a *Statistical Toolbox*, que permitiram aplicar os diferentes algoritmos e avaliar o seu desempenho.

De forma a preservar o maior número de dados possível, bem como, a sua estrutura, o *software* possibilita que valores omissos sejam representados por NaN (*Not a Number*). Assim, é possível conservar a informação conhecida tendo a certeza que os valores representados por NaN não influenciarão o ajuste dos modelos e a posterior análise de desempenho (Beale, Hagan, & Demuth, 2010). Nos subcapítulos seguintes é explanada, em termos gerais, a definição dos diferentes modelos.

3.1.1 Redes neuronais artificiais

As redes neuronais artificiais tentam em certa medida imitar as funcionalidades naturais do cérebro humano, tais como aprender e memorizar. Estas utilizam uma arquitetura muito semelhante à estrutura do cérebro humano e são compostas por simples unidades de processamento, denominadas de neurónios artificiais, com um grande número de interligações (Shukla, Tiwari, & Kala, 2010). A arquitetura perceptrão multicamada com retropropagação do erro foi adotada neste trabalho, e é exemplificada na Figura 1 que se apresenta em seguida.

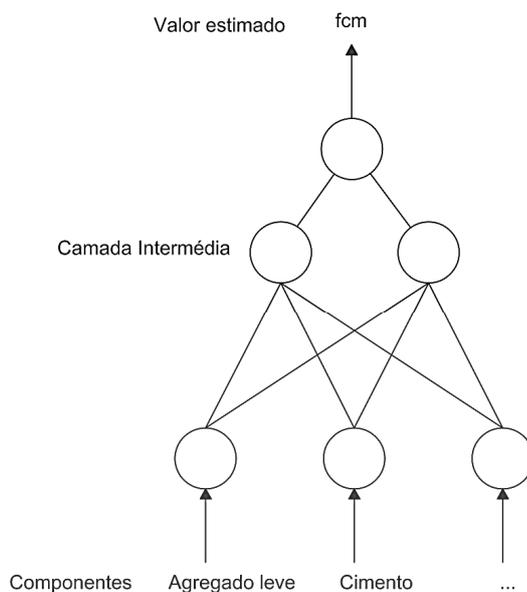


Figura 1- Perceptrão multicamada

A arquitetura perceptrão multicamada tem como base um conjunto de neurónios artificiais interligados. A descrição de um neurónio artificial pode ser feita por uma equação matemática que calcula o valor de saída em função dos valores de entrada. A Figura 2 que se apresenta em seguida permitirá entender melhor a explicação que será feita.

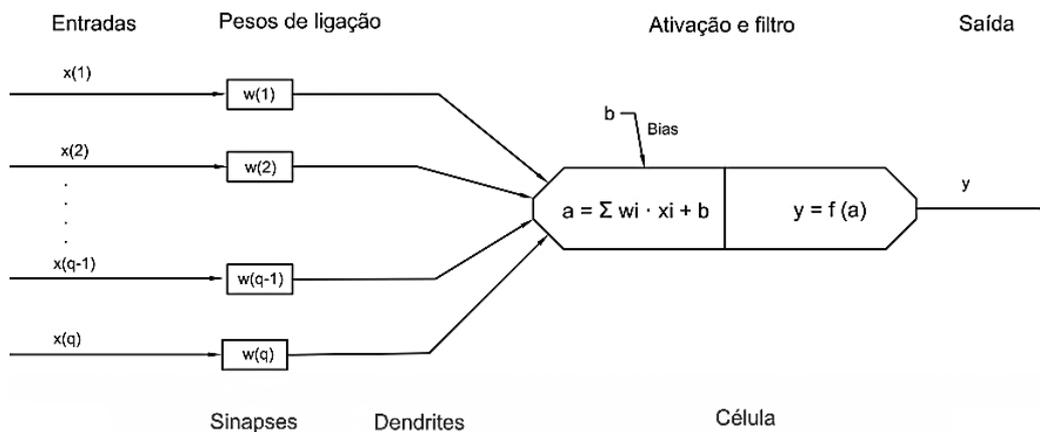


Figura 2 - Modelo de um neurónio artificial

Conforme se pode observar na Figura 2, associado a cada entrada x_i , existe um valor w_i , designado por peso de ligação. À soma ponderada das entradas (a) dá-se o nome de ativação do neurónio que depois de transformada por uma função de ativação ($f(a)$) possibilita a

obtenção da saída y . O *bias* (b) permite obter uma saída não nula quando todas as entradas x_i forem iguais a zero. Os pesos da ligação existentes entre os vários neurónios são parâmetros ajustáveis, que conferem às estruturas neuronais a capacidade de aprendizagem e de colocação da informação na memória. Uma ligação pode funcionar como excitação ou inibição para um neurónio, consoante os pesos da ligação forem positivos ou negativos (Martins, 1997).

Distinguem-se duas fases para o neurónio artificial: a fase de treino, na qual o neurónio aprende que resposta fornecer conforme o sinal de entrada, e a fase de operação ou simulação, na qual o neurónio responde de acordo com o que foi preparado na fase de treino. Durante o treino da rede o algoritmo funciona da seguinte forma: (1) o sinal à entrada de cada neurónio da primeira camada é propagado através da rede, obtendo-se a resposta produzida pela camada de saída; (2) a resposta obtida à saída da rede é comparada à saída desejada, calculando-se o erro; (3) o erro obtido é retropropagado através da rede e os pesos são ajustados, de forma a produzir a resposta correta (Lopes, 2007). O treino da rede é um processo iterativo e acontece até que o erro seja nulo, se verifique determinado número máximo de iterações ou o algoritmo não seja capaz de otimizar mais o modelo (há convergência para um valor de erro que pode não ser o desejado).

3.1.1.1 Modelação das redes neuronais artificiais

A função de treino utilizada tem como fundamento o método de Regularização Bayesiana. Foram testadas outras funções de treino mas o tamanho da base de dados acabou por definir a função de treino empregue. Para pequenas bases de dados esta função possibilita uma boa capacidade de generalização pois não requer um conjunto de dados para validação (Beale, Hagan, & Demuth, 2010). Assim, de forma aleatória, são considerados oitenta e cinco por cento dos dados para ajustar o modelo e quinze por cento para avaliar o erro dos valores previstos pelo modelo (já ajustado). A função minimiza a combinação de erros e pesos, determinando ao mesmo tempo, a sua combinação ideal que permite a correta generalização do modelo. Os pesos e *bias* são gerados por uma função de aprendizagem cuja base é o método de gradiente e momento. Neste caso, está a ser utilizada uma taxa de aprendizagem de 0.01 e um momento constante de 0.90 (valores padrão do *software*).

O modelo base da rede é constituído por uma camada intermédia. Não há um método que possibilite determinar o número de camadas intermédias a utilizar. Contudo, conforme indicado na bibliografia, apenas em casos muito específicos é que o número de camadas intermédias é superior a um (Shukla, Tiwari, & Kala, 2010). Regra geral, o desenvolvimento do modelo inicia-se sempre com uma camada intermédia e apenas no caso do treino da rede não se realizar é que se poderá analisar o possível aumento do número de camadas intermédias.

O número de neurónios da camada intermédia é definido por um processo iterativo. A inexistência de regras que especifiquem o número de neurónios a considerar conforme o tipo de problema obriga a que assim o seja. Desta forma, com base na bibliografia, considera-se adequado desenvolver modelos para um número de neurónios compreendido entre dois e vinte (Beale, Hagan, & Demuth, 2010). Neste sentido, é adotado um incremento de dois neurónios para cada modelo desenvolvido. Através da análise do erro é selecionado o modelo que, com o menor número de neurónios, possibilite a obtenção de melhores resultados.

O número de neurónios da camada intermédia está associado ao desempenho do modelo e, regra geral, o desempenho melhora com o aumento do número de neurónios. No entanto é necessário algum cuidado na definição do número de neurónios da camada intermédia pois um melhor desempenho do modelo para um dado conjunto de dados em análise não significa que este (o modelo) apresente bons resultados para um conjunto de dados diferente. Por este motivo é selecionado o modelo que, com um menor número de neurónios, permita obter melhores resultados.

Para que seja possível uma maior eficiência no desenvolvimento do modelo, os dados utilizados na fase de treino são pré processados por uma função. Com efeito, é executada uma normalização para que os dados se situem no intervalo entre menos um e um. No final, os dados são pós processados de forma a serem apresentados na sua forma original. Neste contexto, a função de ativação considerada é a tangente hiperbólica ($\tanh(x)$). A função é contínua e diferenciável em todo o seu domínio, bem como, limitada superior e inferiormente ($[-1,1]$).

3.1.2 k-Vizinhos mais próximos

O algoritmo k-Vizinhos Mais Próximos é um algoritmo simples, usado para efetuar análises de classificação e regressão. Em ambos os tipos de análise o valor de um objeto é influenciado pelos valores dos seus vizinhos (restantes objetos) mais próximos. O parâmetro “ k ” define o número de vizinhos a ser considerado na análise e o seu valor ótimo pode ser obtido, por exemplo, por validação cruzada.

De forma a procurar as proximidades dos objetos é necessário medir a distância entre eles através de uma função. Esta distância é determinada a partir de um vetor posição num espaço multidimensional. Numa análise de regressão o valor atribuído ao objeto é a média dos valores dos seus k-vizinhos mais próximos. Em seguida apresenta-se a Figura 3 para explicar o funcionamento do algoritmo.

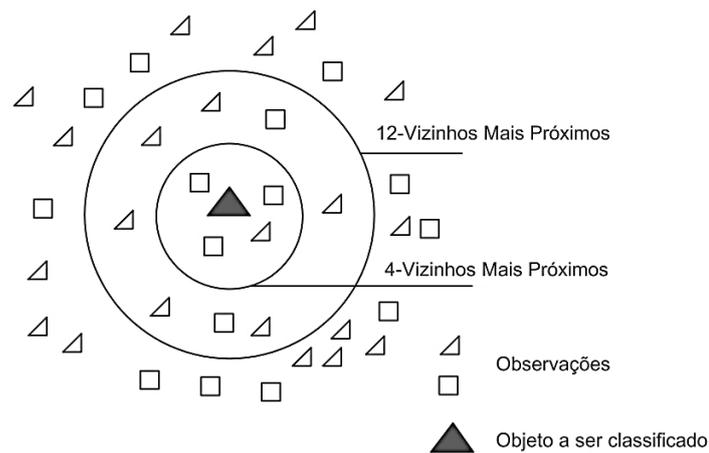


Figura 3 - k-Vizinhos mais próximos aplicado à classificação

A Figura 3 mostra um simples problema de classificação com duas classes de objetos: quadrados e triângulos. O círculo interior contém quatro vizinhos mais próximos enquanto o círculo exterior contém doze vizinhos mais próximos. Para o círculo interior, uma vez que o número de quadrados (três) é superior ao número de triângulos (um), o algoritmo classificará o objeto como quadrado. Contudo, para o círculo exterior a classificação do objeto será triângulo, pois o número de triângulos é sete e o número de quadrados é cinco.

3.1.2.1 Modelação de k-vizinhos mais próximos

De acordo com a bibliografia, e depois de terem sido avaliadas outras funções, a função utilizada para medir a distância entre os objetos é a Euclidiana (Hastie, Tibshirani, & Friedman, 2011). O parâmetro k , que define o número de vizinhos a considerar na análise, é determinado por validação cruzada. Para diferentes valores de k o conjunto de dados é dividido em cinco subconjuntos com um número de registos aproximadamente igual. São executadas dez iterações utilizando 4/5 dos registos para ajustar o modelo e 1/5 para o testar. O valor final do erro obtido por validação cruzada é a média dos obtidos nas dez iterações. O valor de k para o qual se obtém o menor valor final de erro é o utilizado para o desenvolvimento do modelo.

3.1.3 Árvores de regressão

Uma árvore de decisão é um algoritmo com uma estrutura em árvore na qual um teste baseado em atributos é estabelecido em cada nó interno (Witten, Frank, & Hall, 2011). Estas árvores são designadas de árvore de regressão quando aplicadas com o objetivo de prever o valor de uma variável contínua. A Figura 4 que se apresenta abaixo mostra o exemplo de uma árvore de regressão.

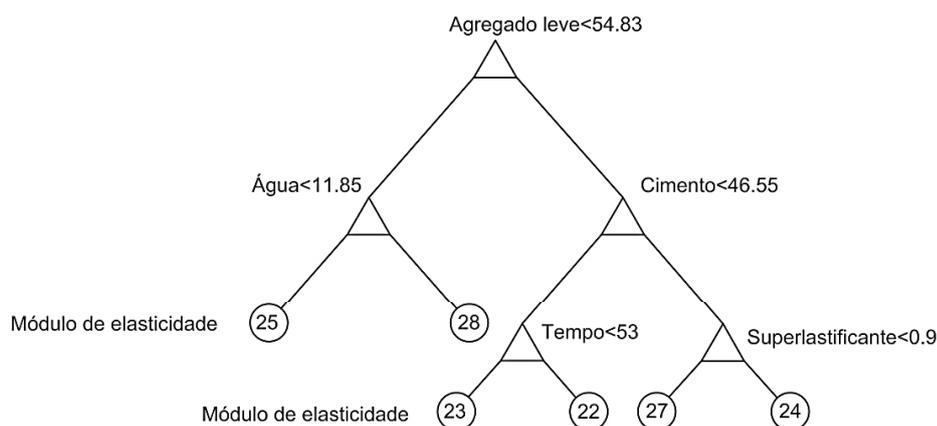


Figura 4 - Árvore de regressão

Os nós externos da árvore são designados de folhas e indicam o valor para um determinado atributo. No presente trabalho a árvore de regressão é binária pelo que, em cada nó, o teste efetuado divide o conjunto de dados em dois subconjuntos. Dessa divisão resultam dois

ramos que representam dois valores possíveis para os atributos. A divisão é efetuada de modo que cada subconjunto seja mais homogéneo. O algoritmo tende a escolher as variáveis que possibilitam o maior número de divisões para os testes em cada nó interno, sendo que, a mesma variável pode ser utilizada mais do que uma vez em níveis diferentes.

3.1.3.1 Modelação das árvores de regressão

A divisão em cada nó da árvore é realizada com base no erro quadrático médio para um número mínimo de cinco observações. Com base nesta divisão, o nó seguinte da árvore apresenta possíveis valores de atributos com menor probabilidade de erro. A profundidade da árvore é definida através do número de observações a considerar em cada folha. É considerado um número mínimo de dez observações para os nós internos, e o número de observações por folha (nó externo) é estabelecido por validação cruzada. Para diferentes números de observações a considerar em cada folha, o conjunto de dados é dividido em cinco subconjuntos com um número de registos aproximadamente igual. Posteriormente são executadas dez iterações utilizando 4/5 dos registos para ajustar o modelo e 1/5 para o testar. O valor final do erro obtido por validação cruzada é a média dos obtidos nas dez iterações. O modelo é desenvolvido com o número de observações por folha que apresentar menor valor de erro final.

3.2 Avaliação dos modelos

O desempenho dos diferentes modelos é avaliado e comparado através de diferentes medidas de erro entre os valores reais e previstos. As medidas de erro utilizadas neste trabalho são o Erro Absoluto (Equação 3.1) e o Erro Relativo (Equação 3.2):

$$E_{Absoluto} = \frac{1}{N} \times \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.1)$$

$$E_{Relativo} = \frac{E_{Absoluto}}{\frac{\sum_{i=1}^N |y_i - \bar{y}|}{N}} \times 100 \quad (3.2)$$

Nas equações N representa o número de registos, y_i designa o valor real, \hat{y}_i o valor estimado pelo modelo considerado e \bar{y} a média dos valores reais.

O modelo com melhor desempenho é identificado através dos seguintes gráficos: Erro relativo vs. Tempo e Valor Estimado vs. Valor Desejado. Desta forma, o modelo com menor área abaixo da curva Erro Relativo vs. Tempo e com correlação mais forte entre os Valores Estimados e Desejados é considerado como aquele que apresenta melhor desempenho.

Tal como explicado no subcapítulo respeitante à modelação, os modelos k-Vizinhos Mais Próximos e Árvore de Regressão são desenvolvidos com base na avaliação do erro médio, neste caso, obtido por validação cruzada para dez iterações. O erro medido para os modelos k-Vizinhos Mais Próximos é o relativo enquanto para os algoritmos baseados na Árvore de Regressão é medido o absoluto. Os modelos relativos às Redes Neurais Artificiais são avaliados através da análise do erro quadrático e do desempenho do algoritmo para as fases de treino e teste.

Posteriormente ao desenvolvimento dos modelos, estes são avaliados para misturas de referência de modo a identificar o modelo com melhor desempenho. Depois de identificado o modelo com melhor desempenho, comparam-se os valores estimados por este com os previstos pelas equações do Eurocódigo para a propriedade mecânica em causa.

3.3 Análise da base de dados

As bases de dados usadas neste trabalho derivam de um conjunto de ensaios mecânicos realizados no Laboratório de Engenharia Estrutural da Universidade do Minho para caracterizar betão leve de elevada resistência. Para produzir este material, foram escolhidas matérias-primas disponíveis de qualidade, produzidos os provetes e avaliadas as propriedades mecânicas mais relevantes para o comportamento dos elementos estruturais que utilizem este material.

Foram produzidas várias misturas (misturas de referência) para estudar e avaliar as propriedades relevantes do betão leve. As misturas de referência correspondem a amassaduras que foram realizadas com o objetivo específico de estudar as diferentes propriedades do betão leve. Todas as restantes amassaduras tiveram o intuito de produzir material para ser utilizado em ensaios experimentais relativos a um trabalho de investigação que decorreu na Universidade do Minho. No âmbito desse trabalho, realizaram-se várias amassaduras, para as quais se realizaram sempre ensaios de resistência à compressão e módulo de elasticidade. O

conjunto de resultados obtidos nesse âmbito resultou na base de dados que é agora utilizada no âmbito da presente dissertação de Mestrado Integrado.

Os testes de resistência à compressão foram efetuados em provetes cúbicos de 100 mm e provetes cilíndricos com 150 mm de diâmetro e 300 mm de altura. Efetuaram-se, ainda, testes para medir o módulo de elasticidade, a resistência à tração e a densidade. Todos os testes foram efetuados para diferentes idades do betão leve, com o objetivo de definir a evolução das suas propriedades ao longo do tempo.

A base de dados referente à Densidade corresponde a trinta e sete misturas distintas e é constituída por um total de quarenta e quatro valores de densidade, registados para diferentes instantes de tempo. Os valores variam entre 1771.8 e 1981.9 kg/m³, pelo que, de acordo com a classificação apresentada na NP EN 206-1 (2007), os valores compreendem as classes de massa volúmica D1.8 e D2.0. O registo dos valores de densidade, efetuado ao longo do tempo, pode ser consultado na Figura 29 do anexo A.1.

A base de dados respeitante à Resistência à Compressão de Provetes Cúbicos corresponde a doze misturas distintas e é composta por um total de vinte e quatro registos efetuados ao longo do tempo. Os valores existentes na base de dados abrangem os 55 e os 77 MPa. O registo dos valores da resistência à compressão de provetes cúbicos, concretizado ao longo do tempo, pode ser consultado na Figura 30 do anexo A.1.

A base de dados relativa à Resistência à Compressão de Provetes Cilíndricos corresponde a quarenta e seis misturas diferentes e é constituída por um total de cinquenta registos efetuados para diferentes instantes de tempo. Os valores existentes na base de dados compreendem os 52 e os 66 MPa. O registo de valores de resistência à compressão de provetes cilíndricos, realizado ao longo do tempo, pode ser visto na Figura 31 do anexo A.1.

A base de dados respeitante ao Módulo de Elasticidade corresponde a trinta e sete misturas distintas e é formada por um total de quarenta e quatro valores, medidos ao longo do tempo. Os valores que constam na base de dados variam entre 22 e 28.5 GPa. O registo de valores de módulo de elasticidade, efetuado ao longo do tempo, pode ser visto na Figura 32 do anexo A.1.

A base de dados alusiva à Resistência à Tração corresponde a três misturas distintas e é constituída por um total de sete valores de resistência à tração, medidos ao longo do tempo. Os valores de resistência à tração variam entre os 2.8 e os 4 MPa. O registo de valores de resistência à tração, realizado para diferentes instantes de tempo, pode ser observado na Figura 33 do anexo A.1.

As variáveis (componentes da mistura) presentes na base de dados são: quantidade de agregado leve de argila expandida (densidade igual a $750\pm 50 \text{ Kg/m}^3$), quantidade de areia natural (graduada entre 0 e 4.76 mm), quantidade de cimento (CEM I 52.5R), volume de água, volume de agente redutor de água (superplastificante), teor de água na areia natural, teor de água na argila expandida e o instante de tempo (dias) correspondente à idade do espécime.

4 RESULTADOS OBTIDOS

4.1 Densidade

O modelo da Rede Neuronal Artificial para a qual se apresentam os resultados obtidos tem na sua camada intermédia 4 neurónios. Os elementos que serviram de base à definição do número de neurónios da camada intermédia, bem como a justificação do número definido, podem ser consultados no anexo A.2, designadamente no Quadro 21 e Figura 34.

O modelo respeitante ao algoritmo k-Vizinhos Mais Próximos para o qual se apresentam os resultados obtidos tem um valor k igual a 2. A informação que permitiu concluir quanto ao valor do parâmetro k a considerar encontra-se no Quadro 22 do anexo A.2.

O modelo da Árvore de Regressão para o qual se apresentam os resultados obtidos tem 2 observações por folha. Este número é o que nas dez iterações efetuadas por validação cruzada permitiu obter menor erro. Os resultados do processo de validação cruzada encontram-se no Quadro 23 do anexo A.2.

Os valores de densidade estimados pelos diferentes modelos são avaliados para as misturas de referência B16 e B42, cuja constituição pode ser observada no Quadro 2 que se indica em seguida.

Quadro 2 - Misturas de referência B16 e B42

	B16	B42
Betonagem (l)	100	105
Arlita F7 (kg)	52.5	55.1
Areia Natural (kg)	48.2	50.6
CEM 52,5 R (kg)	47.5	55.5
Água (l)	15.5	15
Superplastificante (l)	0.75	1
TH Areia (%)	-	1.9
TH Arlita (%)	-	8.3

De forma a aferir o modelo com melhor desempenho, apresenta-se em seguida a Figura 5. Nesta figura é possível observar o erro relativo dos valores estimados pelos diferentes modelos para cada instante de tempo para a mistura B16.

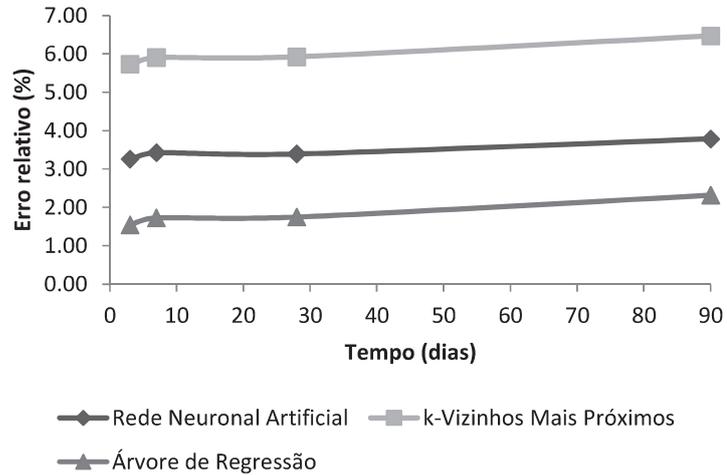


Figura 5 - Mistura B16, erro relativo vs. tempo para cada modelo

Da observação da Figura 5, constata-se que a Árvore de Regressão é o modelo cujos valores estimados mostram menor valor de erro. Prossegue-se a análise dos resultados obtidos com a apresentação da Figura 6 e do Quadro 3. A figura estabelece a comparação entre a densidade estimada e a medida, enquanto o quadro apresenta os valores de densidade estimados.

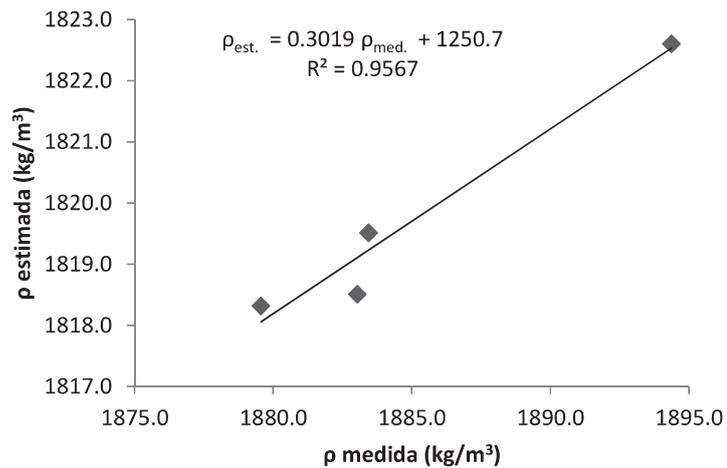


Figura 6 - Mistura B16, densidade estimada vs. densidade medida para rede neuronal artificial

Quadro 3 - Densidade estimada

Mistura de referência	Tempo (dias)	Densidade medida (kg/m ³)	Densidade estimada (kg/m ³)		
			Rede neuronal artificial	k-Vizinhos mais próximos	Árvore de regressão
B16	3	1879.6	1818.3	1771.8	1850.6
B16	7	1883.0	1818.5	1771.8	1850.6
B16	28	1883.4	1819.5	1771.8	1850.6
B16	90	1894.4	1822.6	1771.8	1850.6
B42	7	1811.5	1817.4	1771.8	1783.9
B42	28	1842.6	1818.4	1771.8	1783.9

Conforme é possível constatar no Quadro 3, os valores de densidade estimados pela Árvore de Regressão e k-Vizinhos Mais Próximos são constantes. Observa-se que independentemente do instante de tempo o valor de densidade estimado é sempre o mesmo. A Rede Neuronal Artificial é o único modelo cujos valores de densidade estimados não são constantes ao longo do tempo (Figura 6).

Para que seja possível concluir quanto ao modelo com melhor desempenho, é apresentado em seguida o Quadro 4. Neste quadro encontram-se os valores de erro associados aos valores de densidade estimados por cada modelo para os instantes de tempo e misturas em análise.

Quadro 4 – Erro associado à densidade estimada

Mistura de referência	Tempo (dias)	Rede neuronal artificial		k-Vizinhos mais próximos		Árvore de regressão	
		Erro absoluto (kg/m ³)	Erro relativo (%)	Erro absoluto (kg/m ³)	Erro relativo (%)	Erro absoluto (kg/m ³)	Erro relativo (%)
B16	3	61.2	3.3	107.7	5.7	29.0	1.5
B16	7	64.5	3.4	111.2	5.9	32.4	1.7
B16	28	63.9	3.4	111.6	5.9	32.9	1.7
B16	90	71.8	3.8	122.5	6.5	43.8	2.3
B42	7	5.9	0.3	39.7	2.2	27.6	1.5
B42	28	24.2	1.3	70.7	3.8	58.6	3.2

Através da análise do Quadro 4 é possível observar que a Rede Neuronal Artificial e a Árvore de Regressão são os modelos cujos valores estimados mostram menor valor de erro. A diferença entre os erros obtidos para a Árvore de Regressão e para a Rede Neuronal Artificial

é substancial. Assim, apresenta-se abaixo o Quadro 5 com a média do erro para ambas misturas de forma identificar-se o melhor modelo.

Quadro 5 - Média do erro para as misturas em causa

Mistura de referência	Tempo (dias)	Rede neuronal artificial		k-Vizinhos mais próximos		Árvore de regressão	
		Erro absoluto (kg/m ³)	Erro relativo (%)	Erro absoluto (kg/m ³)	Erro relativo (%)	Erro absoluto (kg/m ³)	Erro relativo (%)
B16	7	64.5	3.4	111.2	5.9	32.4	1.7
B16	28	63.9	3.4	111.6	5.9	32.9	1.7
B42	7	5.9	0.3	39.7	2.2	27.6	1.5
B42	28	24.2	1.3	70.7	3.8	58.6	3.2
Média		39.6	2.1	83.3	4.5	37.9	2.0

Analisando o Quadro 5 verifica-se que, para o mesmo período de tempo, a diferença entre a média dos erros obtidos para a Árvore de Regressão e para Rede Neuronal Artificial não é significativa. Nesse sentido, para que seja possível estimar o valor de densidade de betão leve para uma dada mistura ao longo do tempo, considera-se a Rede Neuronal Artificial o modelo com melhor desempenho.

4.2 Resistência à compressão

4.2.1 Resistência à compressão de provetes cúbicos

O modelo da Rede Neuronal Artificial para o qual se apresenta os resultados obtidos contém 10 neurónios na camada intermédia. A justificação quanto à definição do número de neurónios e toda a informação relevante que a suporta encontra-se no Quadro 24 e, nas Figuras 36 e 37, presentes no anexo A.3.

O modelo desenvolvido através do algoritmo k-Vizinhos Mais Próximos para o qual se apresentam os resultados obtidos tem parâmetro k igual a 2. A informação referente à definição do valor deste parâmetro, pode ser consultada no Quadro 25 do anexo A.3.

A Árvore de Regressão desenvolvida tem 3 observações por folha. Este é o número para o qual das dez iterações de validação cruzada efetuadas se verificou o menor valor médio de

erro. Os elementos obtidos por validação cruzada que permitiram definir o número de observações adotado apresentam-se no Quadro 26 do anexo A.3.

Os valores estimados pelos diferentes modelos são avaliados para as misturas de referência B2, B4 e B8. A constituição destas misturas pode ser vista no Quadro 6 que se apresenta em seguida.

Quadro 6 – Misturas de referência B2, B4 e B8

	B2	B4	B8
Betonagem (l)	90	100	110
Arlita F7 (kg)	47.4	47.4	54.6
Areia natural (kg)	47.8	47.8	53.0
CEM 52,5 R (kg)	47.5	47.5	52.2
Água (l)	12.5	15.5	13.7
Superplastificante (l)	0.7	0.8	0.8
TH Areia (%)	2.8	1.8	3.5
TH Arlita (%)	1.1	-	12.7

De forma a avaliar os resultados obtidos pelos diferentes modelos começa-se por apresentar em seguida o Quadro 7. Neste quadro expõem-se os valores de erro associados à resistência à compressão de provetes cúbicos estimada pelos diferentes modelos.

Quadro 7 – Erro associado ao valor estimado da resistência à compressão de provetes cúbicos

Mistura de referência	Tempo (dias)	Rede neuronal artificial		k-Vizinhos mais próximos		Árvore de regressão	
		Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)
B2	7	4.5	6.5	11.0	15.9	8.7	12.6
B2	28	8.9	12.0	8.6	11.6	7.0	9.5
B4	7	7.4	12.9	2.3	4.0	3.3	5.8
B4	28	4.2	6.8	5.7	9.4	6.2	10.1
B8	7	0.8	1.2	9.5	14.7	2.4	3.8
B8	28	0.5	0.7	0.9	1.4	0.2	0.4

Com base na análise do Quadro 7 constata-se que os maiores valores de erro verificam-se para o modelo k-Vizinhos Mais Próximos, nomeadamente para as misturas B2 e B8 (instante de tempo igual a 7 dias). A Rede Neuronal Artificial e a Árvore de Regressão exibem um melhor desempenho.

Para que seja possível concluir quanto ao modelo que apresenta melhor desempenho, se a Rede Neuronal Artificial ou a Árvore de Regressão, apresenta-se em baixo o Quadro 8. Neste quadro podem observar-se os valores de resistência à compressão de provetes cúbicos estimados por cada modelo.

Quadro 8 – Valor estimado da resistência à compressão de provetes cúbicos

Mistura de referência	Tempo (dias)	Resistência à compressão medida (MPa)	Resistência à compressão estimada (MPa)		
			Rede neuronal artificial	k-Vizinhos mais próximos	Árvore de regressão
B2	7	69.5	64.9	58.4	60.7
B2	28	74.0	65.1	65.4	66.9
B4	7	57.4	64.8	55.1	60.7
B4	28	60.8	64.9	55.1	66.9
B8	7	63.1	63.9	55.1	60.7
B8	28	64.5	64.1	62.2	64.8

Através da análise do Quadro 8 verifica-se que os valores estimados pela Árvore de Regressão para misturas B2 e B4, independentemente do instante de tempo, são iguais. O facto de as misturas terem uma constituição semelhante (Quadro 6) motiva que tal se verifique, conforme se pode notar na Figura 7 que se apresenta em baixo, com o esquema da Árvore de Regressão.

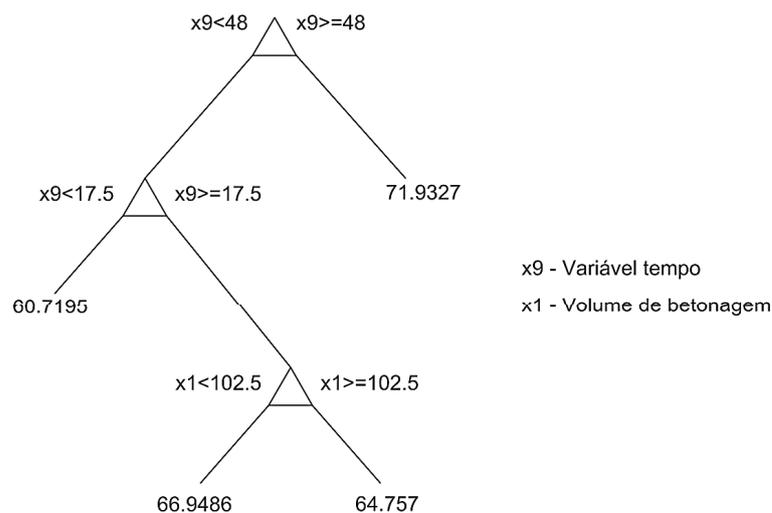


Figura 7 - Esquema da árvore de regressão

Conclui-se assim que perante o objetivo de estimar a resistência à compressão de provetes cúbicos, ao longo do tempo, a Rede Neuronal Artificial é o modelo que melhor se adequa.

4.2.2 Resistência à compressão de provetes cilíndricos

O modelo referente à Rede Neuronal para a qual se apresentam os resultados obtidos é constituído por 16 neurónios na camada intermédia. A justificação relativa ao número de neurónios definidos encontra-se no anexo A.4 e, é efetuada com base no Quadro 27 e Figura 38 presentes no referido anexo.

O modelo k-Vizinhos Mais Próximos para o qual se apresentam os resultados obtidos tem parâmetro k igual a 2. A justificação relativa ao valor do parâmetro adotado pode ser vista no Quadro 28 do anexo A.4.

O modelo referente à Árvore de Regressão é constituído por 5 observações por folha. Este número de observações corresponde ao menor valor de erro médio obtido para um total de dez iterações de validação cruzada. A informação resultante das iterações realizadas pode ser consultada no Quadro 29 que se encontra no anexo A.4.

A análise dos resultados obtidos pelos diferentes modelos é efetuada para as misturas de referência B15 e B16. A constituição destas misturas pode ser vista no Quadro 9 que se apresenta em seguida.

Quadro 9 – Constituição das misturas de referência B15 e B16

	B15	B16
Betonagem (l)	80	100
Arlita F7 (kg)	42	52.5
Areia Natural (kg)	38.6	48.2
CEM 52,5 R (kg)	38	47.5
Água (l)	10	15.5
Superplastificante (l)	0.6	0.8
TH Areia (%)	0.1	-
TH Arlita (%)	15.6	-

Com objetivo de identificar o modelo que apresenta melhor desempenho indica-se em seguida a Figura 8. Nesta figura é possível observar o erro relativo aos valores estimados por cada modelo, para cada instante de tempo em consideração (3, 7, 28 e 90 dias).

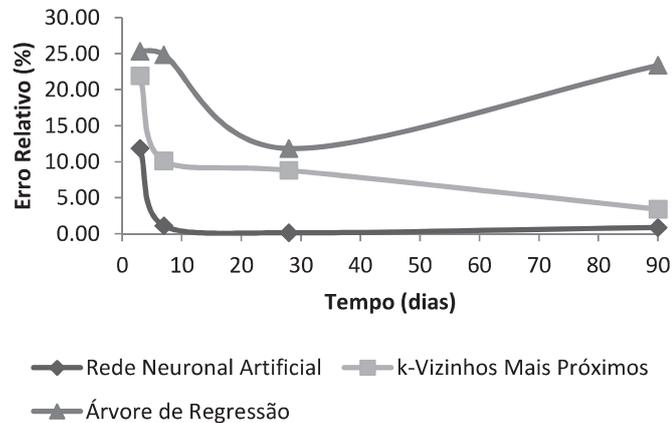


Figura 8 - Mistura B15, erro relativo vs. Tempo

Através da observação da Figura 8 verifica-se que a Rede Neuronal Artificial é o modelo com melhor desempenho pois é o que apresenta menor área abaixo da curva Erro Relativo vs. Tempo. A avaliação dos modelos prossegue com a apresentação das seguintes Figuras: 9, 10 e 11. Nestas figuras pode-se observar para a mistura B15 e, para cada um dos modelos e instantes de tempo em causa, a comparação entre os valores de resistência à compressão de provetes cilíndricos estimados e medidos.

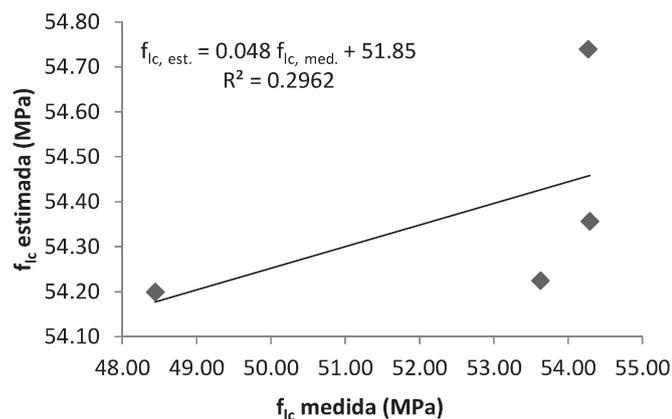


Figura 9 - Rede neuronal artificial, comparação entre a resistência à compressão de provetes cilíndricos estimada e medida

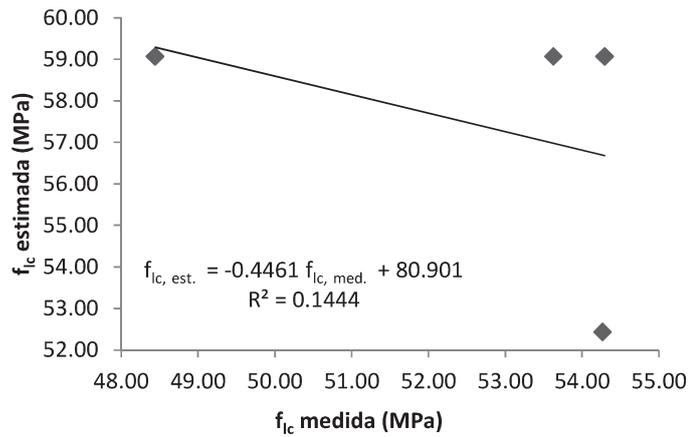


Figura 10 - k-Vizinhos mais próximos, comparação entre a resistência à compressão de provetes cilíndricos estimada e medida

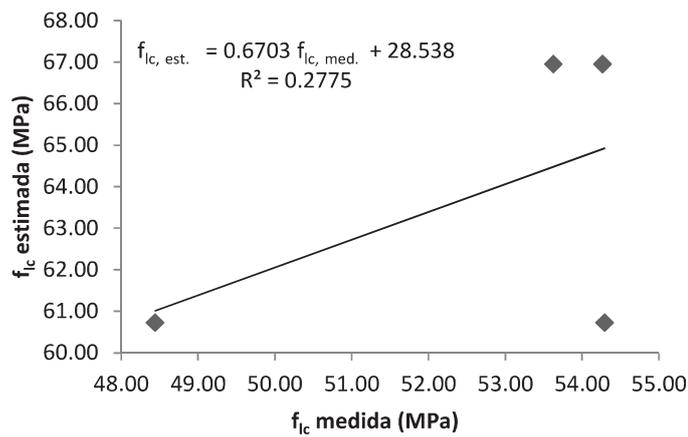


Figura 11 - Árvore de regressão, comparação entre a resistência à compressão de provetes cilíndricos estimada e medida

Da observação das figuras constata-se que para todos os modelos a relação entre os valores medidos e os estimados é reduzida, sendo que a melhor relação verifica-se para a Rede Neuronal Artificial. É então possível concluir que a Rede Neuronal Artificial é o modelo com melhor desempenho. No sentido de analisar a relação entre os valores estimados pela Rede Neuronal Artificial e os medidos apresenta-se em baixo o Quadro 10. Neste quadro indicam-se os valores de erro associados à resistência à compressão de provetes cilíndricos estimada pelos diferentes modelos.

Quadro 10 – Erro associado ao valor estimado de resistência à compressão de provetes cilíndricos

Mistura de referência	Tempo (dias)	Rede neuronal artificial		k-Vizinhos mais próximos		Árvore de regressão	
		Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)
B15	3	5.8	11.9	10.6	21.9	12.3	25.3
B15	7	0.6	1.1	5.4	10.1	13.3	24.8
B15	28	0.1	0.1	4.8	8.8	6.4	11.8
B15	90	0.5	0.9	1.8	3.4	12.7	23.4
B16	3	10.3	21.4	8.3	17.3	12.4	25.7
B16	7	-	-	-	-	-	-
B16	28	6.6	12.8	4.5	8.7	8.6	16.6
B16	90	2.8	4.9	0.4	0.7	8.5	15.2

Através da análise do Quadro 10 e da observação da Figura 9 conclui-se que, para a mistura B15, a relação entre os valores medidos e os estimados pela Rede Neuronal Artificial é prejudicada pela diferença na ordem de grandeza dos erros obtidos. Nomeadamente para o instante de tempo igual a três dias, a ordem de grandeza do erro que se verifica é significativamente diferente da dos restantes. De forma a entender o porquê de tal, apresenta-se em seguida a Figura 12 onde se pode observar o número de registos ao longo do tempo (que constituem a base de dados utilizada na fase de treino), e a Figura 13 na qual para a mistura B15 se pode ver a relação entre o erro relativo e o número de registos entre os três e os sete dias.

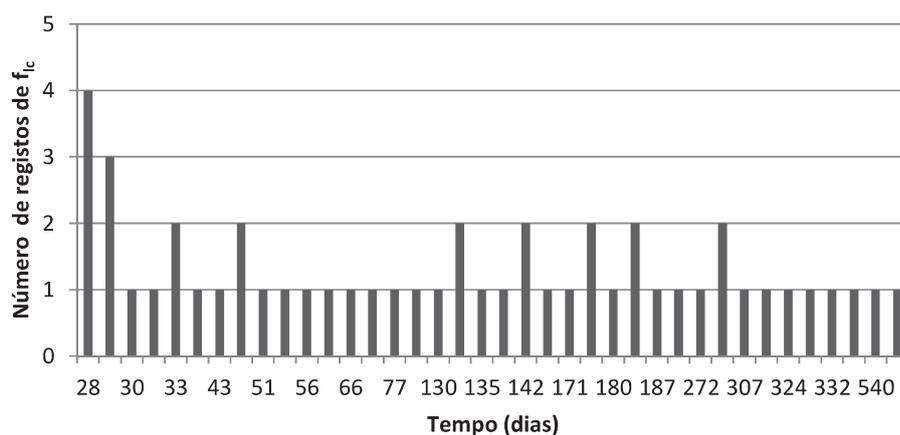


Figura 12 - Número de registos de resistência à compressão de provetes cilíndricos conforme o instante de tempo

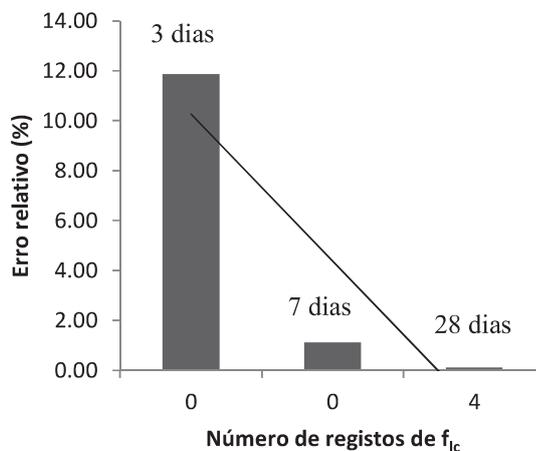


Figura 13 - Erro relativo conforme o número de registos

Como se pode observar na Figura 12, não existem na base de dados utilizada na fase de treino, registos para o intervalo de tempo compreendido entre os zero e vinte e oito dias. Desta forma, é justificável que valores de resistência estimados pela Rede Neuronal Artificial ou qualquer um dos outros modelos para, o intervalo de tempo compreendido entre os zero e vinte e oito dias, apresentem valor de erro significativamente superior ao dos estimados para, os dias posteriores a esse intervalo. A Figura 13 apresenta esse fato para a mistura B15. De fato, os valores estimados para os três e sete dias apresentam um erro significativo quando comparados com o estimado para os vinte e oito dias.

Em seguida efetua-se a comparação entre os valores estimados pelo modelo com melhor desempenho (Rede Neuronal Artificial) e os estimados pelo Eurocódigo. A Norma Portuguesa NP EN 1992-1-1 (2010) propõe uma equação para estimar o valor da resistência à compressão para o betão de densidade normal em diferentes idades. O coeficiente $\beta_{cc}(t)$, das equações (4.1) e (4.2) estabelece a relação entre a resistência média à compressão do betão, medida aos 28 dias de idade, e a resistência à compressão medida numa outra idade qualquer.

$$f_{cm}(t) = \beta_{cc}(t) \cdot f_{cm} \quad (4.1)$$

$$\beta_{cc}(t) = \exp \left\{ s \left[1 - \left(\frac{28}{t} \right)^{1/2} \right] \right\} \quad (4.2)$$

Nas equações (4.1) e (4.2), t corresponde à idade do betão no momento em consideração, enquanto s é um coeficiente que tem em conta o tipo de cimento. Para o presente caso s tem o valor de 0.2 (cimento 52.5 R).

Com o objetivo de comparar e analisar os valores da resistência estimados pela Rede Neuronal Artificial e pelo modelo da NP EN 1992-1-1 (2010), apresenta-se em baixo a Figura 14 e o Quadro 11. A Figura 14 representa, para a mistura B15, o gráfico Erro Relativo vs. Tempo, enquanto o Quadro 11 apresenta os erros associados aos valores estimados pela Rede Neuronal Artificial e pelo modelo da NP EN 1992-1-1 (2010).

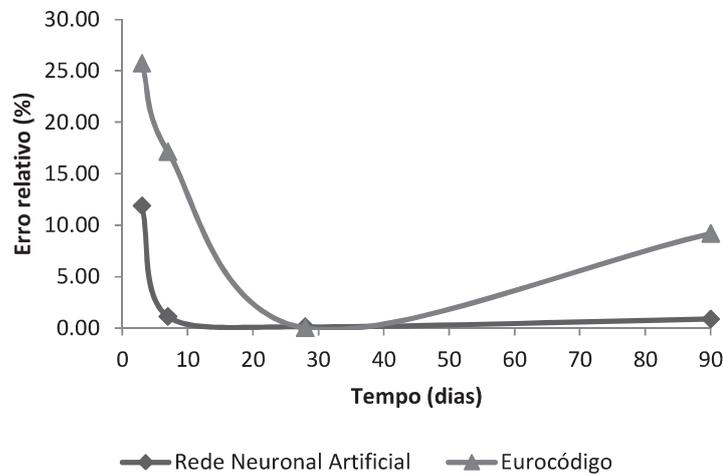


Figura 14 - Mistura B15, erro relativo vs. tempo

Quadro 11 – Erro associado ao valor estimado da resistência à compressão de provetes cilíndricos

Mistura de referência	Tempo (dias)	Rede neuronal artificial		Eurocódigo	
		Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)
B15	3	5.8	11.9	12.5	25.7
B15	7	0.6	1.1	9.2	17.1
B15	28	0.1	0.1	0.0	0.0
B15	90	0.5	0.9	5.0	9.2
B16	3	10.3	21.4	13.8	28.5
B16	7	-	-	-	-
B16	28	6.6	12.8	0.0	0.0
B16	90	2.8	4.9	0.7	1.2

Através da observação da Figura 14 verifica-se que para a mistura B15 a Rede Neuronal Artificial desenvolvida produz resultados com um erro inferior ao do Eurocódigo. A área abaixo da curva respeitante ao erro relativo dos valores estimados pelo Eurocódigo ao longo do tempo é superior à observada para a Rede Neuronal Artificial.

No entanto, através da análise do Quadro 11 verifica-se que para a mistura B16 os valores estimados pela Rede Neuronal Artificial exibem um erro superior aos estimados pelo Eurocódigo. O facto de a mistura poder encontrar-se mal caracterizada na base de dados, isto é, não existirem registos suficientes que permitam à rede durante a fase de aprendizagem adquirir a informação de que necessita para estimar de forma mais exata a resistência, pode justificar a menor precisão da Rede Neuronal Artificial em relação ao Eurocódigo. A relação entre os valores estimados pela Rede Neuronal Artificial e pelo Eurocódigo com os valores medidos é também avaliada através da Figura 15 apresentada em seguida.

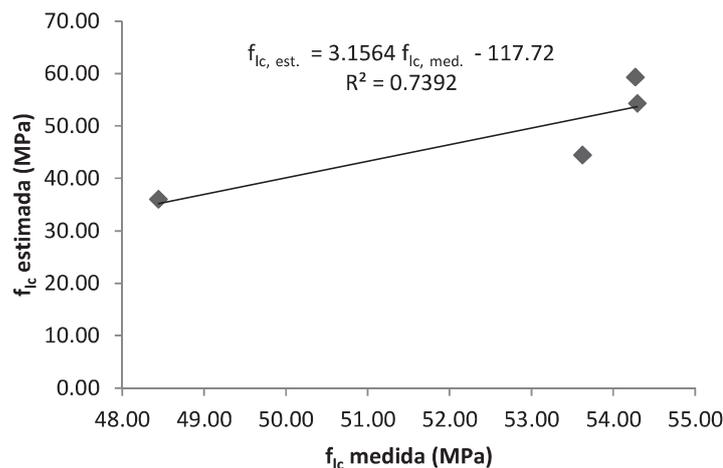


Figura 15 - Mistura B15, comparação entre os valores estimados pela equação (4.2) e os valores medidos

Verifica-se que, para além do Eurocódigo apresentar melhores resultados para a mistura B16, este também apresenta para a mistura B15 uma melhor relação com os valores medidos (Figura 15). A relação entre os valores estimados pela Rede Neuronal Artificial e os medidos é substancialmente inferior à do Eurocódigo (Figura 9). A Rede Neuronal Artificial mostra assim um desempenho inferior ao do Eurocódigo.

4.3 Módulo de elasticidade

O modelo respeitante à Rede Neuronal Artificial para a qual se apresentam os resultados obtidos tem 6 neurónios na camada intermédia. O motivo e os elementos que suportam o número definido podem ser examinados no anexo A.5, nomeadamente o Quadro 30 e as Figuras 39 e 40.

O modelo k-Vizinhos Mais Próximos, para o qual se apresentam os resultados obtidos, tem um parâmetro k igual a 2. A informação que sustenta a definição do parâmetro pode ser consultada no Quadro 31 do anexo A.5.

O modelo de Árvore de Regressão desenvolvido tem 5 observações por folha. Este número de observações corresponde ao menor valor do erro médio que foi obtido para um total de dez iterações do método de validação cruzada. O Quadro 32 através do qual se definiu o número de observações consta no anexo A.5.

Os resultados obtidos são analisados para as misturas de referência B16 e B42. A constituição destas misturas pode ser observada no Quadro 12 que se apresenta em seguida.

Quadro 12 – Misturas de referência B16 e B42

	B16	B42
Betonagem (l)	100	105
Arlita F7 (kg)	52.5	55.1
Areia Natural (kg)	48.2	50.6
CEM 52,5 R (kg)	47.5	55.5
Água (l)	15.5	15.0
Superplastificante (l)	0.7	1.0
TH Areia (%)	-	1.9
TH Arlita (%)	-	8.3

Com o propósito de identificar o modelo com melhor desempenho, apresenta-se em seguida na Figura 16, o erro relativo aos valores do módulo de elasticidade estimado ao longo do tempo por cada modelo para a mistura B16.

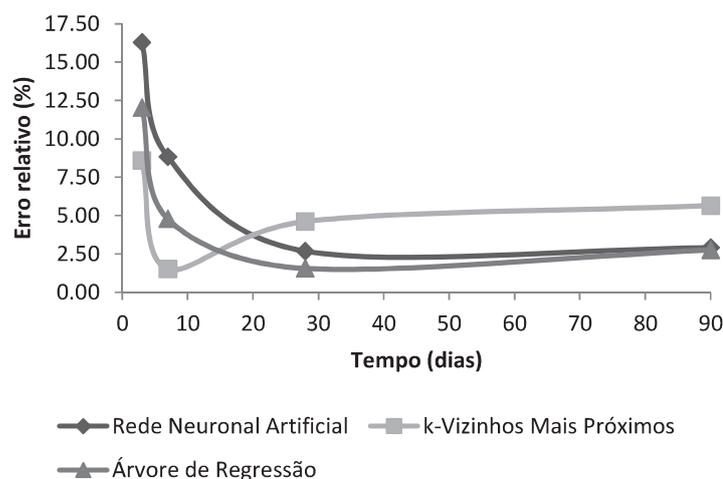


Figura 16 - Erro relativo vs. tempo

Através da observação da Figura 16, constata-se que a Árvore de Regressão é o modelo cujos valores estimados exibem menor erro, o que por si só não é indicativo de que a árvore seja o melhor modelo. Esta constatação é fundamentada pela menor área abaixo da curva Erro Relativo vs. Tempo que a Árvore de Regressão apresenta.

A identificação do modelo com melhor desempenho prossegue com a análise da relação entre os valores estimados por cada modelo e os medidos para a mistura B16. As Figuras 17 e 18 que se apresentam em seguida em conjunto com o Quadro 13 permitem avaliar essa relação.

Quadro 13 – Valor estimado do módulo de elasticidade

Mistura de referência	Tempo (dias)	Módulo de elasticidade medido (GPa)	Módulo de elasticidade estimado (GPa)		
			Rede neuronal artificial	k-Vizinhos mais próximos	Árvore de regressão
B16	3	20.3	23.6	22.0	22.7
B16	7	21.7	23.6	22.0	22.7
B16	28	23.1	23.7	22.0	22.7
B16	90	23.3	24.0	22.0	24.0
B42	7	21.6	23.7	22.4	22.7
B42	28	23.2	23.8	22.4	22.7

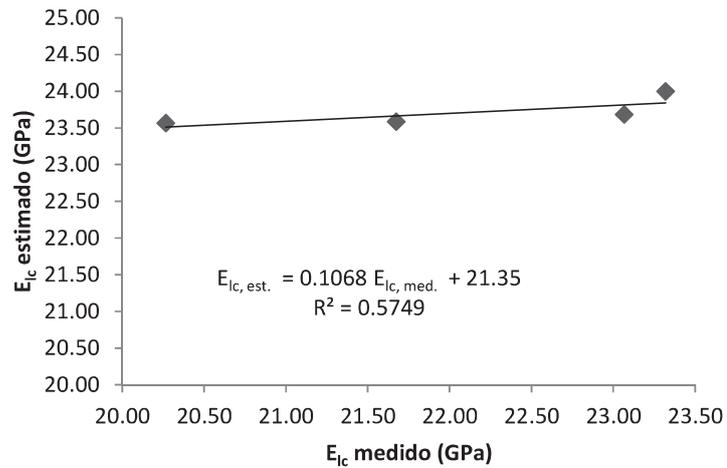


Figura 17 - Rede neuronal artificial, comparação entre os módulos de elasticidade estimado e medido

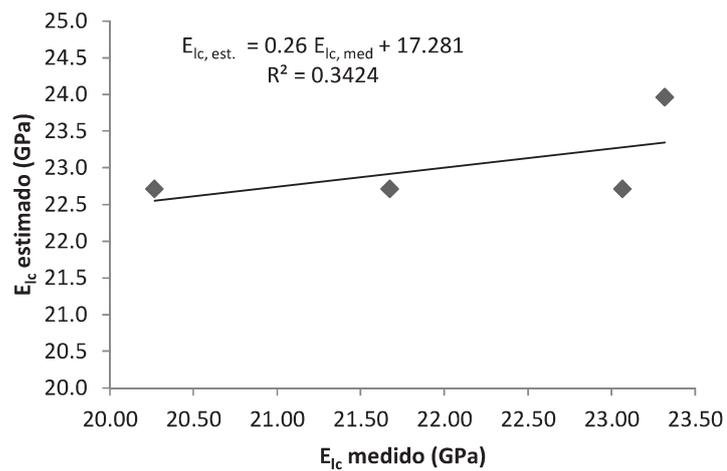


Figura 18 - Árvore de regressão, comparação entre os módulos de elasticidade estimado e medido

Com base na observação das Figuras 17 e 18, verifica-se que a relação entre os valores estimados e medidos para a Rede Neuronal Artificial é superior à da Árvore de Regressão. Para o modelo k-Vizinhos Mais Próximos o valor do módulo de elasticidade estimado é constante no tempo (Quadro 13). De forma a concluir quanto ao modelo com melhor desempenho, apresenta-se em baixo o Quadro 14. No quadro é possível observar para cada um dos modelos os valores de erro obtidos.

Quadro 14 – Erro associado aos valores de módulo de elasticidade estimado

Mistura de referência	Tempo (dias)	Rede neuronal artificial		k-Vizinhos mais próximos		Árvore de Regressão	
		Erro absoluto (GPa)	Erro relativo (%)	Erro absoluto (GPa)	Erro relativo (%)	Erro absoluto (GPa)	Erro relativo (%)
B16	3	3.3	16.3	1.7	8.6	2.4	12.0
B16	7	1.9	8.8	0.3	1.5	1.0	4.8
B16	28	0.6	2.7	1.1	4.6	0.4	1.5
B16	90	0.7	2.9	1.3	5.6	0.6	2.8
B42	7	2.0	9.4	0.7	3.5	1.1	5.0
B42	28	0.6	2.6	0.8	3.4	0.5	2.0

Analisando o Quadro 14 é possível perceber de uma forma clara que, a diferença entre os valores dos erros obtidos para, os módulos de elasticidade estimados pela Rede Neuronal Artificial e Árvore de Regressão não são significativos. Uma vez que os valores do módulo de elasticidade estimados pela Rede Neuronal Artificial apresentam maior relação com os medidos (Figura 17), considera-se a Rede Neuronal Artificial como o modelo com melhor desempenho. Para sustentar esta consideração, apresenta-se em baixo o Quadro 15 com os valores do módulo de elasticidade estimado ao longo do tempo por cada modelo.

Quadro 15 – Módulo de elasticidade estimado pelos diferentes modelos

Mistura de referência	Tempo (dias)	Módulo de elasticidade medido (GPa)	Módulo de elasticidade estimado (GPa)		
			Rede neuronal artificial	k-Vizinhos mais próximos	Árvore de regressão
B16	3	20.3	23.6	22.0	22.7
B16	7	21.7	23.6	22.0	22.7
B16	28	23.1	23.7	22.0	22.7
B16	90	23.3	24.0	22.0	24.0
B42	7	21.6	23.7	22.4	22.7
B42	28	23.2	23.8	22.4	22.7

Constata-se através da análise do Quadro 15 que, face ao objetivo de estimar o módulo de elasticidade ao longo do tempo, a Rede Neuronal Artificial é o único modelo que apresenta capacidade para o fazer de forma adequada. No entanto, para a mistura B16, os valores estimados pela Rede Neuronal Artificial para os instantes de tempo iguais a três e sete dias têm erro substancialmente superior ao dos restantes dias (Quadro 14). Para justificar este fato,

apresentam-se em seguida as Figuras 19 e 20. A Figura 19 apresenta o número de registros do módulo de elasticidade ao longo do tempo (que constituem a base de dados utilizada na fase de treino), enquanto a Figura 20 indica para a mistura B16 e para o período compreendido entre os três e os vinte e oito dias o erro relativo aos valores estimados pela Rede Neuronal Artificial conforme o número de registros existentes.

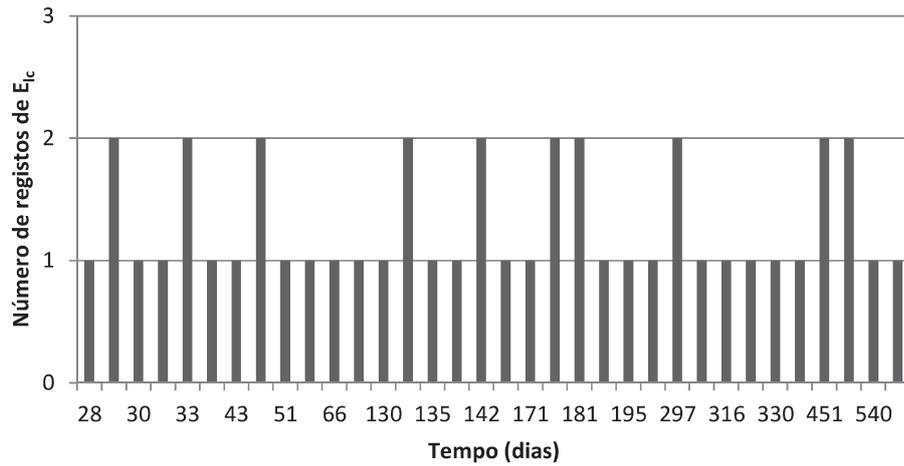


Figura 19 - Número de registros de módulo de elasticidade conforme o instante de tempo

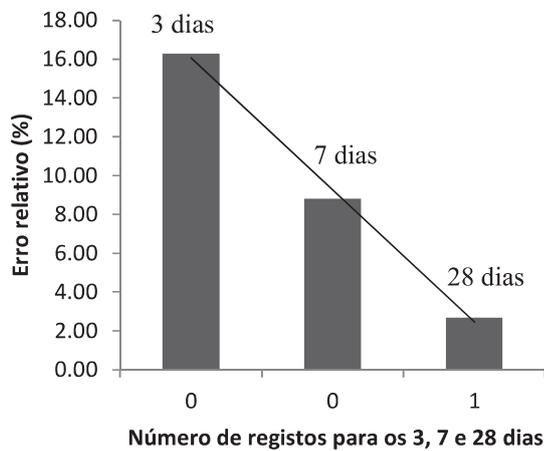


Figura 20 - Erro relativo conforme o número de registros

Na Figura 19 é de notar a inexistência de registros, na base de dados utilizada na fase de treino, para o período compreendido entre os zero e os vinte e oito dias. É assim plausível que

para esse período os valores estimados pela Rede Neuronal Artificial apresentam um erro mais elevado. A Figura 20 sugere isso mesmo, uma vez que, o erro relativo para os vinte e oito dias é significativamente inferior ao que se observa até esse instante.

Em seguida efetua-se a comparação entre os valores estimados pelo modelo com melhor desempenho e os estimados pelo Eurocódigo. A NP EN 1992-1-1 (2010) propõe a Equação (4.4) para determinar o módulo de elasticidade, estabelecida para betões de densidade normal. Este parâmetro é definido como função da resistência à compressão (f_{cm}).

$$E_{cm}(t) = 22 \cdot \left(\frac{f_{cm}}{10}\right)^{0.3} \quad (4.4)$$

No caso do betão leve, a referida norma específica que o módulo de elasticidade pode ser determinado através da afetação da Equação (4.4) por um fator de redução (Equação 4.5). Este fator (η_E) tem em consideração o limite superior da massa volúmica do betão leve (ρ) após secagem em estufa, conforme a classe na qual o betão leve em consideração se insere.

$$E_{lcm}(t) = \eta_E \cdot E_{cm}(t) \quad (4.5)$$

$$\eta_E = (\rho/2200)^2 \quad (4.6)$$

O Quadro 16 que se apresenta em baixo mostra os erros obtidos para os valores estimados pela Rede Neuronal Artificial e pelo modelo do Eurocódigo para a mistura B16.

Quadro 16 – Erro associado aos valores de módulo de elasticidade estimados pela rede neuronal artificial e pelo Eurocódigo

Mistura de referência	Tempo (dias)	Rede neuronal artificial		Eurocódigo	
		Erro absoluto (GPa)	Erro relativo (%)	Erro absoluto (GPa)	Erro relativo (%)
B16	3	3.3	16.3	3.0	14.9
B16	7	1.9	8.8	-	-
B16	28	0.6	2.7	3.4	14.7
B16	90	0.7	2.9	4.2	17.9

Analisando o Quadro 16, conclui-se que os valores estimados pelo modelo do Eurocódigo apresentam, com exceção do instante de tempo igual a três dias, valor de erro superior aos

estimados pela Rede Neuronal Artificial. A Figura 21 que se apresenta em seguida confirma a observação feita.

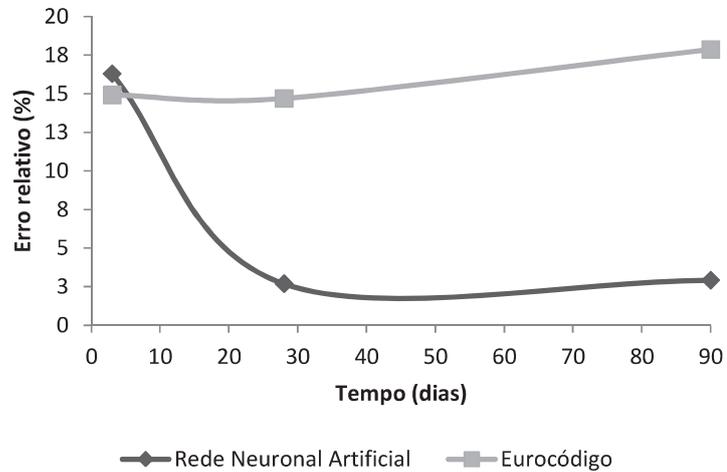


Figura 21 - Mistura B16, erro relativo vs. tempo para a rede neuronal artificial e para o modelo do Eurocódigo

Observando a Figura 21 verifica-se que os valores estimados pela Rede Neuronal Artificial exibem um menor valor de erro. Prosegue-se a análise com a avaliação da relação entre os valores estimados pela Rede Neuronal Artificial e pelo modelo do Eurocódigo, e os valores medidos. Nesse sentido, apresentam-se em baixo as Figuras 22 e 23.

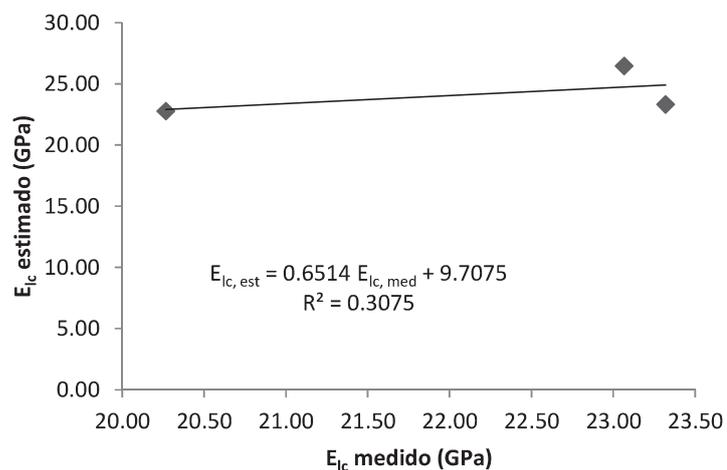


Figura 22 - Mistura B16, comparação entre os valores estimados pelo modelo do Eurocódigo e os valores medidos

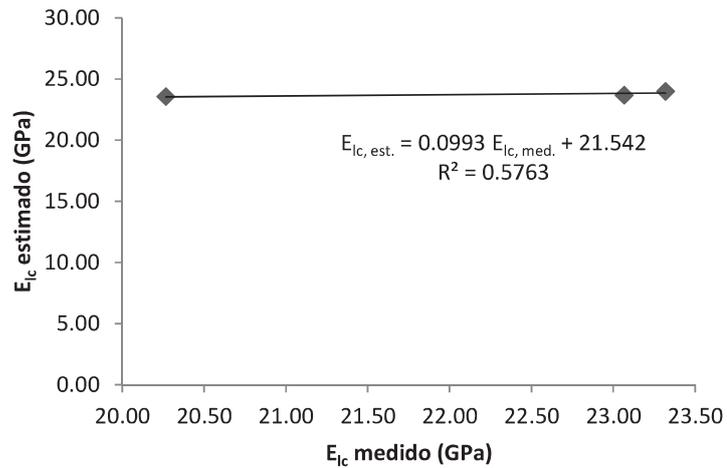


Figura 23 - Mistura B16, comparação entre os valores estimados pela rede neuronal artificial e os valores medidos

Com base na observação das Figuras 22 e 23, constata-se que a relação entre os valores estimados pela Rede Neuronal Artificial e os medidos é superior à do modelo do Eurocódigo. Pode-se então concluir que a Rede Neuronal Artificial é mais precisa.

4.4 Resistência à tração

O modelo referente à Rede Neuronal Artificial para o qual se apresentam os resultados obtidos é composto por 4 neurónios na camada intermédia. As especificações relativas à definição do número de neurónios podem ser vistas no anexo A.6, nomeadamente no Quadro 33 e nas Figuras 41 e 42.

O modelo desenvolvido através do algoritmo k-Vizinhos Mais Próximos para o qual se apresentam os resultados obtidos tem parâmetro k igual a 2. Conforme pode ser visto no Quadro 34 do anexo A.6, é para o valor de k igual a 2 que se obtém o menor número de previsões erradas para o conjunto de dados de treino.

Relativamente à Árvore de Regressão, apesar de se apresentarem resultados, não foi possível obter uma árvore adequada. Devido ao reduzido número de registos de resistência à tração ao longo do tempo, a árvore não é capaz de efetuar os testes de atributos que a caracterizam. O

número de observações por folha considerado é igual a 2. O Quadro 35 do anexo A.6 contém a informação referente à definição do número de observações.

A análise de resultados é realizada para a mistura de referência B15, cuja constituição pode ser vista no Quadro 17 que se indica em baixo.

Quadro 17 – Mistura de referência B15

	B15
Betonagem (l)	80
Arlita F7 (kg)	42.0
Areia Natural (kg)	38.6
CEM 52,5 R (kg)	38.0
Água (l)	10.0
Superplastificante (l)	0.6
TH Areia (%)	0.1
TH Arlita (%)	15.6

De forma a identificar o modelo com melhor desempenho, apresenta-se a Figura 24 na qual é exibida a curva Erro Relativo vs. Tempo para cada modelo.

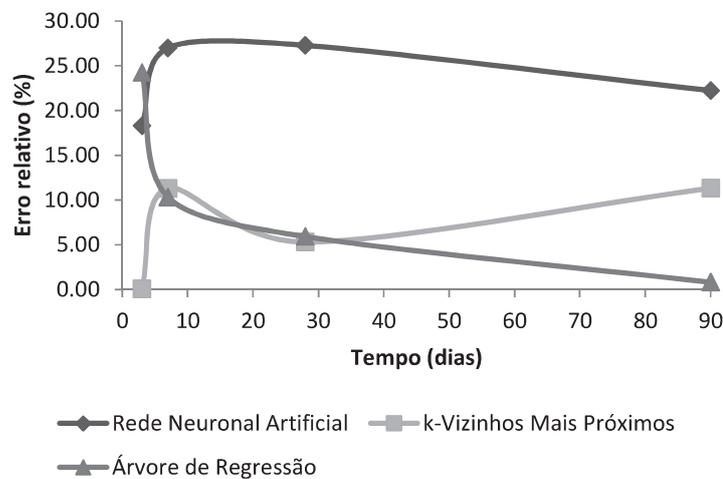


Figura 24 - Erro relativo vs. Tempo

Através da observação da Figura 24, constata-se que a Árvore de Regressão é o único modelo cujos valores de resistência à tração estimados mostram tendência para decrescer no tempo. Assim, para que seja possível concluir quanto ao modelo que apresenta melhor desempenho são apresentadas em baixo as Figuras 25 e 26, bem como, o Quadro 18. As figuras

estabelecem, para cada modelo, a relação entre os valores de resistência à tração estimados e medidos, enquanto o quadro apresenta a resistência à tração estimada pelos modelos.

Quadro 18 – Resistência à tração estimada

Mistura de referência	Tempo (dias)	Resistência à tração medida (MPa)	Resistência à tração estimada (MPa)		
			Rede neuronal artificial	k-Vizinhos mais próximos	Árvore de regressão
B15	3	2.8	2.3	2.8	3.4
B15	7	3.1	2.3	2.8	3.4
B15	28	3.3	2.4	3.1	3.4
B15	90	3.5	2.7	3.1	3.4

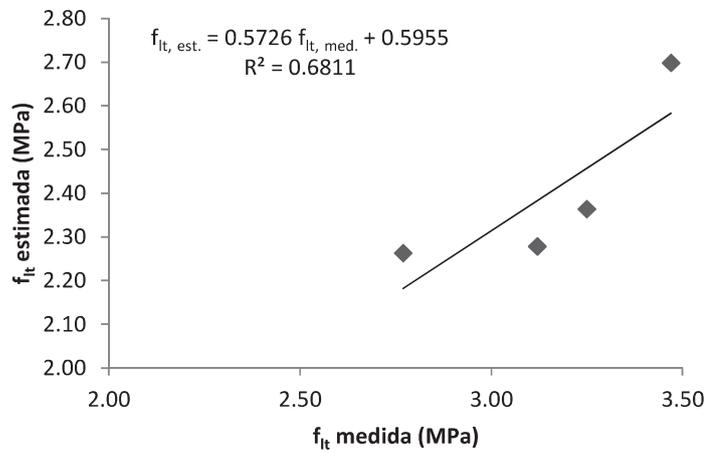


Figura 25 - Relação entre os valores estimados e medidos para rede neuronal artificial

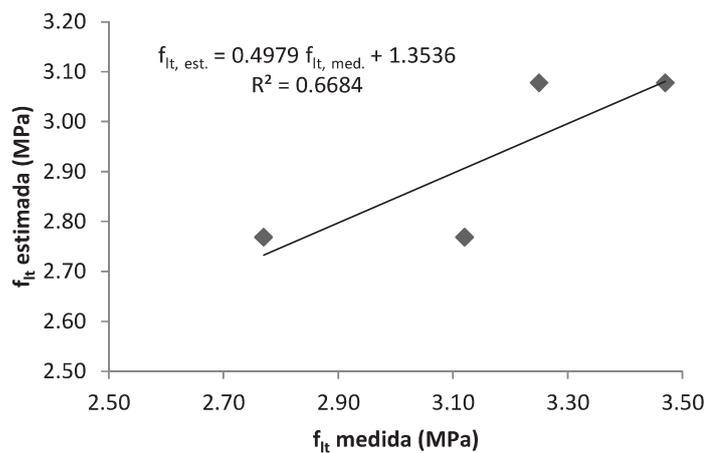


Figura 26 - Relação entre valores estimados e medidos para k-vizinhos mais próximos

Da observação do Quadro 18 verifica-se que a Árvore de Regressão estima um valor de resistência à tração constante ao longo do tempo. Os valores de resistência à tração estimados pela Rede Neuronal Artificial, apesar de apresentarem maior valor de erro (Figura 24), são aqueles que exibem melhor relação com os valores medidos. Assim considera-se a Rede neuronal Artificial como o modelo com melhor desempenho.

Apesar de a Rede Neuronal Artificial ser o modelo cujos valores estimados apresentam maior relação com os medidos (Figura 25), esta verifica-se um pouco baixa, no sentido de que poderia ser mais próxima de um. Para se observar de forma mais clara o motivo pela qual se verifica a baixa relação, apresenta-se em seguida o Quadro 19.

Quadro 19 – Erro associado aos valores de resistência à tração estimados

Mistura de referência	Tempo (dias)	Rede neuronal artificial		k-Vizinhos mais próximos		Árvore de regressão	
		Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)
B15	3	0.5	18.3	0.0	0.1	0.7	24.3
B15	7	0.8	27.0	0.4	11.3	0.3	10.3
B15	28	0.9	27.3	0.2	5.3	0.2	5.9
B15	90	0.8	22.2	0.4	11.3	0.0	0.8

Da análise do Quadro 19 verifica-se que os erros relativos aos valores estimados pela Rede Neuronal Artificial ao longo do tempo têm a mesma ordem de grandeza. O fato do valor dos erros ser algo elevado deve-se ao tamanho da base de dados. O limitado número de diferentes misturas e respetivos resultados de testes de resistência à tração condicionam os valores estimados pela Rede Neuronal Artificial.

Em seguida procede-se à comparação entre os valores de resistência à tração estimados pela Rede Neuronal Artificial e pelo Eurocódigo. De acordo com a NP EN 1992-1-1, é possível determinar a resistência à tração do betão leve a partir da resistência à tração do betão de densidade normal, através das equações (4.7) e (4.8).

$$f_{lctm} = \eta_1 \cdot f_{ctm} \quad (4.7)$$

$$\eta_1 = 0.4 + 0.6 \cdot \rho/2200 \quad (4.8)$$

A referida norma estabelece a relação entre a resistência à tração de betão de densidade normal e a respetiva resistência à compressão com a Equação (4.9).

$$f_{ctm} = 0.3 \cdot f_{ck}^{2/3} \quad (4.9)$$

No Quadro 20 apresentado, constam as medidas de erro adotadas para avaliar e comparar os valores estimados pela Rede Neuronal Artificial e pelo modelo do Eurocódigo.

Quadro 20 – Erro associado aos valores de resistência à tração estimados pela rede neuronal artificial e pelo Eurocódigo

Mistura de referência	Tempo (dias)	Rede Neuronal Artificial		Eurocódigo	
		Erro absoluto (MPa)	Erro relativo (%)	Erro absoluto (MPa)	Erro relativo (%)
B15	3	0.5	18.3	1.2	43.9
B15	7	0.8	27.0	1.1	36.7
B15	28	0.9	27.3	1.1	24.0
B15	90	0.8	22.2	0.8	9.2

Efetuada a análise do Quadro 20, conclui-se que os valores previstos pela Rede Neuronal Artificial apresentam erro absoluto inferior ou igual aos estimados pelo Eurocódigo. O erro relativo aos valores estimados pela Rede Neuronal Artificial verifica-se inferior ao do Eurocódigo até aos sete dias. Nesse sentido, avalia-se a relação entre os valores estimados pela Rede Neuronal Artificial e pelo Eurocódigo com os valores medidos através das Figuras 27 e 28.

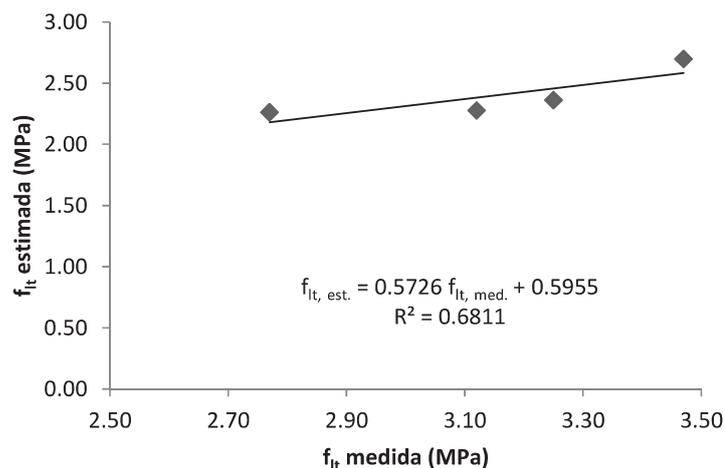


Figura 27 - Comparação entre os valores estimados e medidos para a rede neuronal artificial

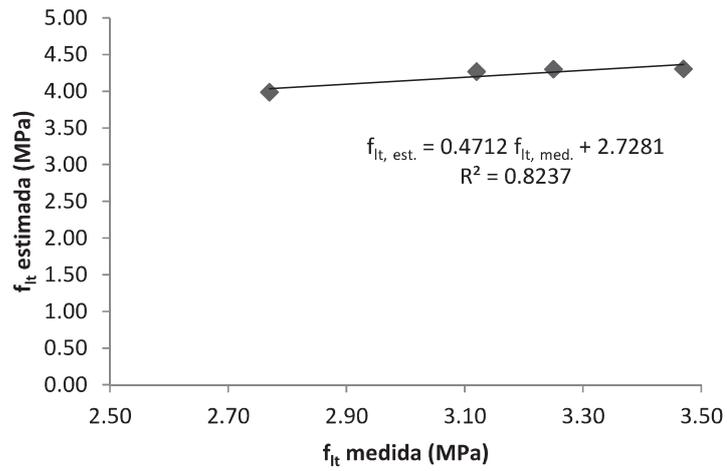


Figura 28 - Comparação entre os valores estimados e medidos para o modelo do Eurocódigo

Conforme se pode ver através das Figuras 27 e 28, os valores previstos pelo modelo do Eurocódigo exibem uma relação com os valores medidos superior à da Rede Neuronal Artificial. Para o presente caso o modelo do Eurocódigo estima de forma mais correta a resistência à tração ao longo do tempo. Tal se deve ao reduzido número de registos da base de dados.

5 CONCLUSÕES

Com base numa base de dados constituída por resultados de ensaios mecânicos realizados pela Universidade do Minho foram aplicadas técnicas *soft computing* com o objetivo de, desenvolver modelos de previsão das propriedades mecânicas de betão leve ao longo do tempo com base nos constituintes de uma dada mistura. As técnicas *soft computing* utilizadas neste trabalho foram nomeadamente: Redes Neurais Artificiais, k-Vizinhos Mais Próximos e Árvores de Regressão. As principais conclusões que se podem retirar deste trabalho são explanadas em seguida.

No que concerne à Densidade, a Rede Neuronal Artificial sugere boa capacidade de generalização pois os valores estimados para as misturas B16 e B42 apresentam um baixo valor de erro. Os valores de densidade estimados pela Rede Neuronal Artificial para a mistura B16 estão próximos dos valores medidos.

O fato da Árvore de Regressão, independentemente do instante de tempo, estimar sempre o mesmo valor de densidade, impossibilita que esta seja considerada como o modelo com melhor desempenho. Neste caso, os valores estimados pela árvore de regressão, bem como, pelo modelo k-Vizinhos Mais Próximos, não apresentam relação com os medidos.

Em relação à resistência à compressão de provetes cúbicos, apesar da Árvore de Regressão estimar valores com menor erro, estes não apresentam relação com os valores medidos. Os testes de atributos efetuados pela árvore não consideram a variável tempo. Desta forma, a Árvore de Regressão não é considerada como sendo o modelo com melhor desempenho.

Relativamente à resistência à compressão de provetes cilíndricos, a ausência de registos para o período de tempo compreendido entre os zero e os vinte e oito dias condiciona o desempenho da Rede Neuronal Artificial. Para esse período, o erro dos valores estimados pela rede apresenta uma ordem de grandeza significativamente diferente da dos restantes dias, prejudicando assim a relação entre os valores estimados e os medidos.

Os valores de resistência à compressão de provetes cilíndricos previstos pela equação apresentada pelo Eurocódigo são mais precisos do que os estimados pela Rede Neuronal

Artificial. A recolha de registos para o período de tempo compreendido entre os zero e os vinte e oito dias permitiria melhorar os resultados obtidos pela Rede Neuronal Artificial.

No que diz respeito ao módulo de elasticidade, os valores estimados pela Árvore de regressão para a mistura B16 são os que apresenta menor erro. No entanto, os valores estimados são constantes ao longo do tempo, pelo que a Árvore de Regressão não é o modelo mais adequado para estimar o módulo de elasticidade ao longo do tempo.

A inexistência de registos de valores do módulo de elasticidade para o período de tempo compreendido entre os zero e vinte e os oito dias, prejudica os resultados obtidos. Os valores estimados pela Rede Neuronal Artificial para esse período mostram um erro ligeiramente superior aos estimados para os dias posteriores a esse período. A recolha de registos para o período compreendido entre zero e vinte e os oito dias beneficiaria os valores estimados pela Rede Neuronal Artificial para esse período.

Com exceção do instante de tempo igual a três dias, a Rede Neuronal Artificial estima valores de módulo de elasticidade com uma precisão superior à da Equação apresentada pelo Eurocódigo. Para instantes de tempo superiores a três dias, os valores estimados pela Rede Neuronal Artificial apresentam um menor erro.

Em relação à resistência à tração, a Árvore de Regressão é o modelo cujos valores estimados apresentam, de um modo geral, menor valor de erro. No entanto, como é objetivo estimar a resistência à tração para cada instante de tempo e tendo em conta que os valores estimados pela Árvore de Regressão são constantes ao longo do tempo, a Árvore de Regressão não é o modelo que apresenta melhor desempenho.

O número de medições de resistência à tração presente na base de dados condicionou os resultados obtidos pela Rede Neuronal Artificial. Com efeito, os valores estimados são pouco precisos, tendo a equação apresentada pelo Eurocódigo melhor desempenho no que concerne à previsão de valores de resistência à tração ao longo do tempo. O enriquecimento da base de dados com um maior número de resultados de testes de resistência à tração, para diferentes misturas, permitiria melhorar o desempenho da Rede Neuronal Artificial.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ACI Committee 213. (1999). *Guide for Structural Lightweight Concrete (ACI 213 R-87)*. ACI - Manual of Concrete Practice.
- Barreto, J. M. (2002). *Introdução às Redes Neurais Artificiais*. Florianópolis: Laboratório de Conexionismo e Ciências Cognitivas UFSC.
- BE 96-3942/R14. (2009). *Structural LWAC: Specification and Guideline for Materials and Production*. EuroLightCon.
- BE 96-3942/R2. (1998). *LWAC Material Properties*. EuroLightCon.
- BE 96-3942/R23. (2000). *Mechanical Properties of Lightweight Aggregate Concrete*. EuroLightCon.
- BE 96-3942/R27. (2000). *Mechanical Properties of LWAC Compared with both NWC and HSC*. EuroLightCon.
- BE 96-3942/R36. (2000). *High Strength LWAC in Construction Elements*. EuroLightCon .
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2010). *Neural Network Toolbox 7 User's Guide*. Massachusetts: The MathWorks, Inc.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. New York: Oxford University Press.
- Chandra, S., & Berntsson, L. (2002). *Lightweight Aggregate Concrete – Science, Technology, and Applications*. New York: Noyes.
- Clark, J. L. (1993). *Structural Lightweight Aggregate Concrete*. London: Chapman & Hall.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From Data Mining to Knowledge discovery in Databases. *AAAI 97*. Rhode Island: AI Magazine.
- Harmon, K. S. (s.d.). *Engineering Properties of Structural Lightweight Concrete*. (C. S. Company, Ed.) Obtido em 2 de 2013, de Stalite: <http://www.stalite.com/uploads/EngineeringProperties.pdf>
- Hastie, T., Tibshirani, R., & Friedman, J. (2011). *The Elements of Statistical Learning – Data Mining, Inference, and Prediction* (2 ed.). New York: Springer.
- Kecman, V. (2001). *Learning and Soft Computing*. London: The MIT Press.
- Kockal, N. U., & Ozturan, T. (2010). Strength and elastic properties of structural lightweight concretes. *Elsevier*.
- Lopes, P. d. (2007). *Detecção de Danos em Estruturas por meio de Técnicas de Redes Neurais Artificiais e Algoritmos Genéticos*. Itajubá: Universidade Federal de Itajubá .

- Martins, F. G. (1997). *Aplicação de Redes Neurais Artificiais em Simulação e Controlo de Processos Químicos*. Porto: Faculdade de Engenharia da Universidade do Porto.
- Mehta, P. K., & Monteiro, P. M. (2006). *Concrete: Microstructure, Properties and Materials* (3 ed.). New York: McGraw-Hill.
- Neville, A. M. (1994). *Properties of Concrete* (3 ed.). England: Longman.
- NP EN 1992-1-1. (2010). *Eurocódigo 2: Projeto de estruturas de betão – Parte 1: Regras gerais e regras para edifícios*. Lisboa: Instituto Português da Qualidade.
- NP EN 206-1. (2007). *Betão. Parte 1: Especificação, desempenho, produção e conformidade*. Lisboa: Instituto Português da Qualidade.
- Shukla, A., Tiwari, R., & Kala, R. (2010). *Real Life Applications of Soft Computing*. New York: Taylor and Francis Group.
- Valente, M. I. (2007). *Estudo Experimental de Sistemas de Conexão para Pontes Mistas de Aço e Betão Leve*. Guimarães: Universidade do Minho.
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques* (3 ed.). United States: Morgan Kaufmann.
- Zupan, J., & Gasteiger, J. (1993). *Neural Networks for Chemists*. New York: VCH.

ANEXOS

A.1

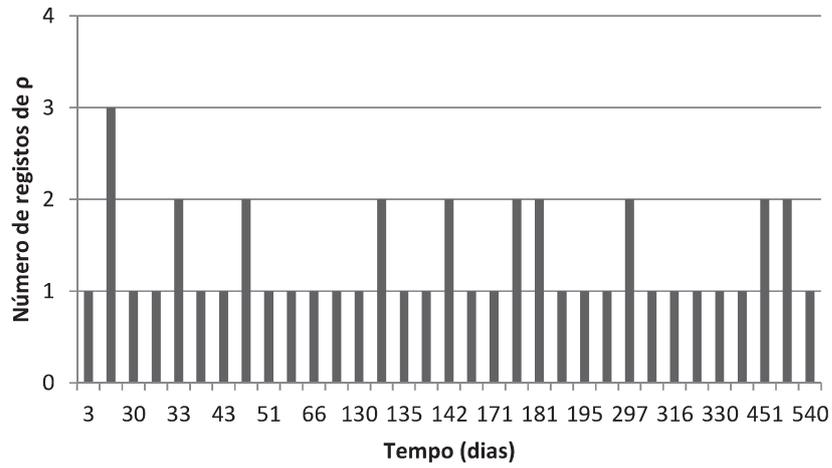


Figura 29 - Número de registros de densidade conforme o instante de tempo

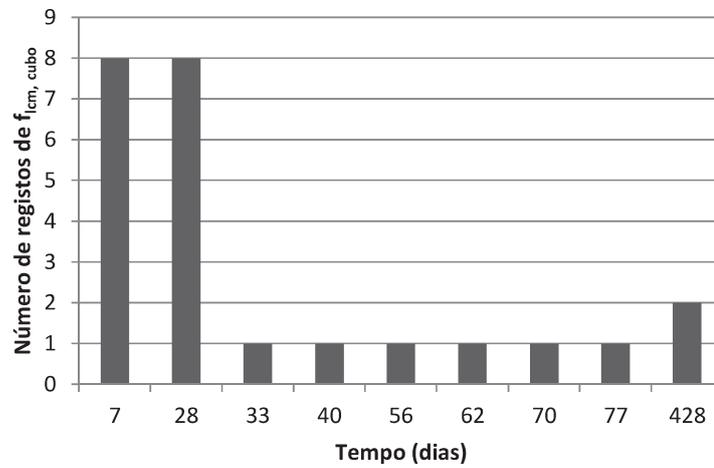


Figura 30 - Número de registros de resistência à compressão de provetes cúbicos conforme o instante de tempo

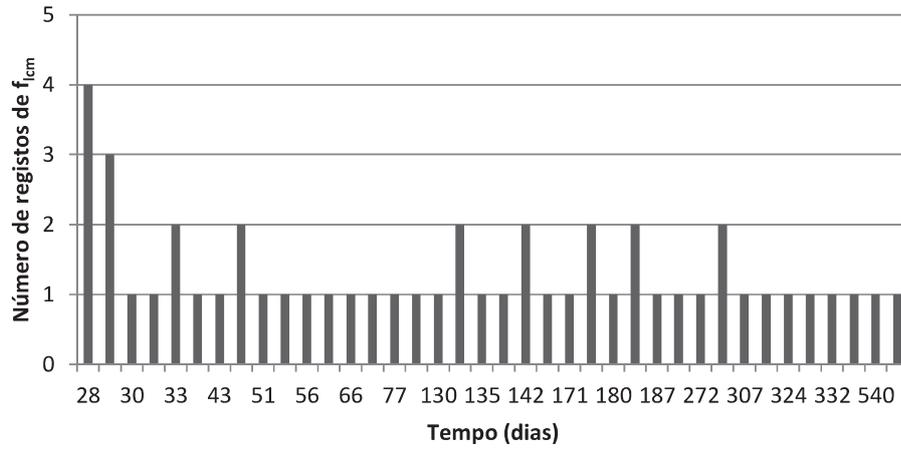


Figura 31 - Número de registros de resistência à compressão de provetes cilíndricos conforme o instante de tempo

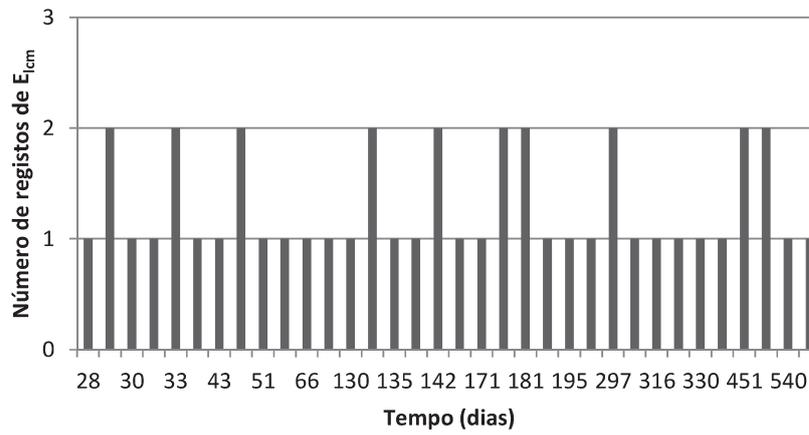


Figura 32 - Número de registros de módulo de elasticidade conforme o instante de tempo

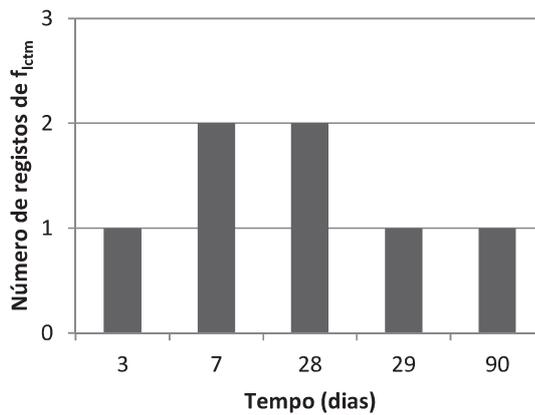


Figura 33 - Número de registros de resistência à tração conforme o instante de tempo

A.2

O número de neurónios da camada intermédia foi definido através do Quadro 21 e da Figura 34 que se apresentam em baixo.

Quadro 21 - Erro quadrático para os diferentes modelos de redes neuronais artificiais

	Número de neurónios da camada intermédia									
	2	4	6	8	10	12	14	16	18	20
$R_{\text{fase de treino}}$	0.73	0.72	0.74	0.70	0.72	0.74	0.69	0.74	0.70	0.74
$R_{\text{fase de teste}}$	0.93	0.77	0.81	0.92	0.87	0.83	0.97	0.89	0.94	0.92
$R_{\text{médio}}$	0.83	0.75	0.78	0.81	0.80	0.78	0.83	0.81	0.82	0.83

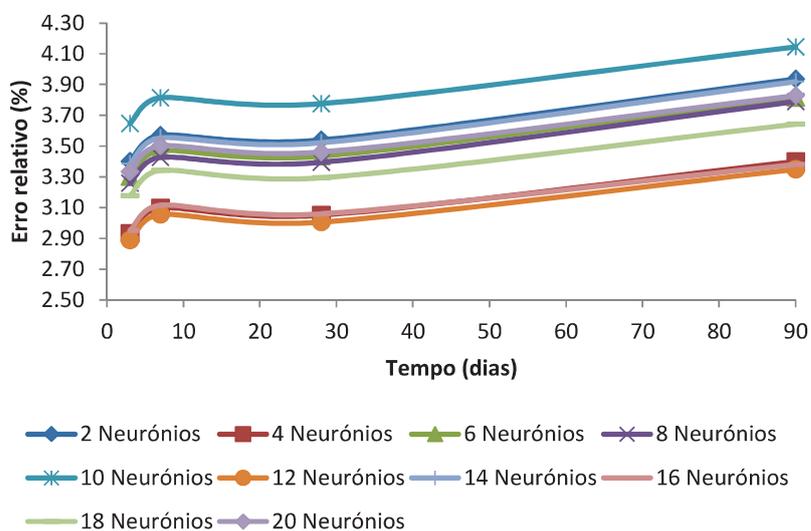


Figura 34 - Mistura B16, erro relativo vs. tempo para os diferentes modelos de redes neuronais artificiais

Os modelos com 4, 12 e 16 neurónios na camada intermédia apresentam aproximadamente a mesma área abaixo da curva Erro Relativo vs. Tempo (Figura 34). De forma a observar de forma mais clara os valores de erro relativo para estes três modelos apresenta-se em seguida a Figura 35.

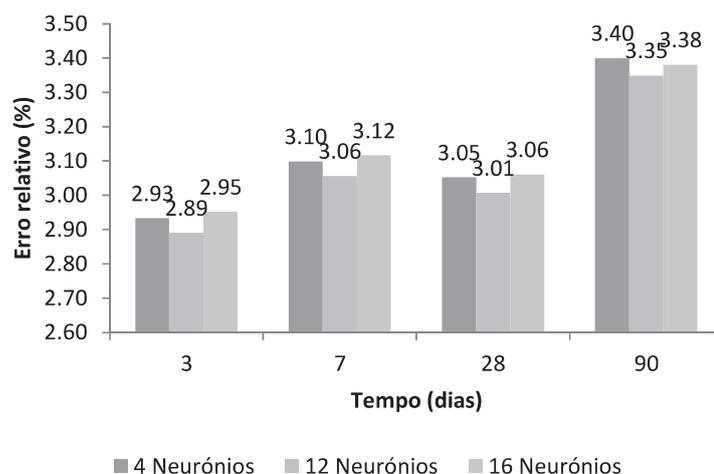


Figura 35 - Mistura B16, série referente aos erros relativos ao longo do tempo

Através da análise do Quadro 21 verifica-se que de entre os três modelos em causa o de 4 neurónios é aquele que, para a fase de teste da rede, apresenta menor relação com os valores desejados. No entanto, as Figuras 34 e 35 indicam que o modelo de 4 neurónios apresenta boa capacidade de generalização pois, o erro relativo não difere significativamente dos modelos com 12 e 16 neurónios. Desta forma, como os modelos de 12 e 16 neurónios apresentam maior risco de uma adaptação desmesurada aos dados de treino, é utilizado o modelo de 4 neurónios.

Relativamente ao modelo k-Vizinhos Mais Próximos não foi possível obter o parâmetro k por validação cruzada pois, nas dez iterações realizadas a percentagem de erro obtida foi sempre igual a cem por cento. Assim, não foi possível concluir qual o valor de k que permitia obter o menor número de previsões erradas para a fase de teste.

Deste modo, recorreu-se ao Quadro 22 que se indica em seguida. No quadro, para os valores de k considerados, apresenta-se a o erro médio referente à fração de previsões erradas por cada modelo para os dados de treino.

Quadro 22 – Valor do erro conforme o valor de k

	Valor do parâmetro k		
	2	3	4
Erro médio (%)	48	68	74

Com base na análise do Quadro 22 o modelo k-Vizinhos Mais Próximos utilizado tem parâmetro k igual a 2, uma vez que, é aquele que apresenta menor erro médio.

No que concerne à definição do número de observações por folha da Árvore de Regressão apresenta-se em seguida o Quadro 23. O quadro indica, para diferentes números de observações, o erro obtido para cada iteração de validação cruzada e a média do erro das dez iterações.

Quadro 23 – Erro médio obtido por validação cruzada para diferentes números de observações por folha

Iteração	Erro absoluto (kg/m^3) conforme o número de observações por folha			
	2	3	4	5
1	50.22	56.04	60.75	63.93
2	56.82	66.56	56.76	73.40
3	55.77	55.20	68.94	58.56
4	57.56	50.47	62.85	66.28
5	63.56	70.70	60.19	60.60
6	56.11	57.03	54.60	55.95
7	55.88	62.12	58.88	62.33
8	59.41	56.71	56.16	56.61
9	58.75	68.54	53.20	60.57
10	65.93	63.93	64.36	58.44
Média	58.15	61.05	59.84	61.87

Através da análise do Quadro 23, o modelo utilizado é constituído por 2 observações por folha pois, é aquele que nas dez iterações realizadas apresenta menor erro médio.

A.3

De forma a definir o número de neurónios da camada intermédia da Rede Neuronal Artificial foram utilizados o Quadro 24 e, as Figuras 36 e 37 que se apresentam em seguida. Nas figuras constam gráficos de barras, nos quais o eixo-x representa os instantes de tempo considerados e, o eixo-y representa o erro relativo à resistência estimada por cada um dos diferentes modelos desenvolvidos. O quadro apresenta o erro quadrático para as fases de treino e teste de cada rede neuronal artificial.

Quadro 24 – Erro quadrático para os diferentes modelos de redes neuronais artificiais

	Número de neurónios da camada intermédia									
	2	4	6	8	10	12	14	16	18	20
$R_{\text{fase de treino}}$	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.93
$R_{\text{fase de teste}}$	0.99	0.97	0.96	0.97	0.97	0.98	0.95	0.95	0.97	0.98
$R_{\text{médio}}$	0.96	0.95	0.95	0.96	0.95	0.96	0.95	0.95	0.95	0.95

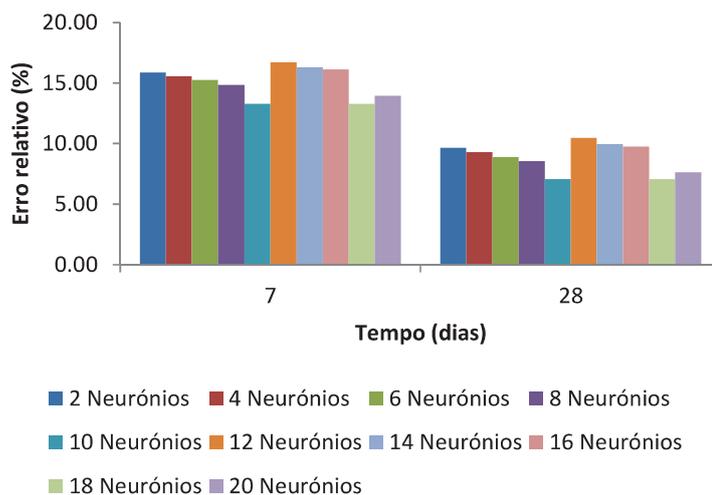


Figura 36 - Mistura B4, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais

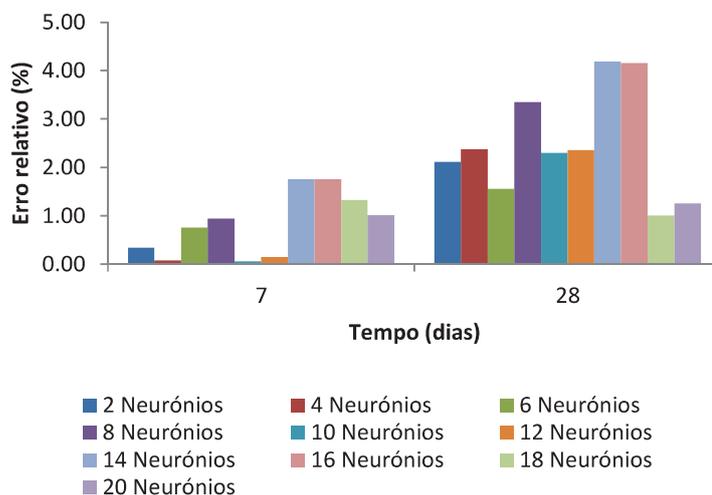


Figura 37 - Mistura B8, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais

Com base na observação da Figura 36 verifica-se que os modelos constituídos por 8 e 10 neurónios são aqueles que com menor número de neurónios apresentam menor erro. Contudo, para a mistura B8, a Figura 37 evidencia que o erro referente ao modelo de 8 neurónios é significativamente superior ao de 10 neurónios. Desta forma, como o erro quadrático para as fases de treino e teste (Quadro 24) de ambos os modelos é idêntico, foi utilizado o modelo constituído por 10 neurónios.

No que diz respeito ao modelo k-Vizinhos Mais Próximos não foi possível obter o parâmetro k por validação cruzada, uma vez que, nas dez iterações realizadas a percentagem de erro obtida foi sempre igual a cem por cento. Assim, não foi possível identificar o valor de k que permitia obter o menor número de previsões erradas para a fase de teste.

Deste modo, foi utilizado o Quadro 25 que se apresenta em seguida. No quadro, para cada valor de k considerado, é indicado o erro médio referente à fração de previsões erradas por cada modelo para os dados de treino.

Quadro 25 – Valor do erro conforme o valor de k

	Valor do parâmetro k		
	2	3	4
Erro médio (%)	53	73	73

Através da análise do Quadro 25, o modelo k-Vizinhos Mais Próximos utilizado tem parâmetro k igual a 2, uma vez que, é aquele que apresenta menor erro médio.

Relativamente à definição do número de observações por folha da Árvore de Regressão apresenta-se em seguida o Quadro 26. O quadro indica, para diferentes números de observações, o erro obtido para cada uma das dez iterações de validação cruzada realizadas e a média do erro referente ao número total de iterações.

Quadro 26 - Erro médio Obtido por validação cruzada para diferentes números de observações por folha

Iteração	Erro absoluto (MPa) conforme o número de observações por folha			
	2	3	4	5
1	3.48	3.45	3.27	3.68
2	3.58	3.42	3.67	4.10
3	3.89	3.32	3.08	4.69
4	3.51	3.09	3.52	3.82
5	3.26	3.36	4.20	3.39
6	3.36	3.16	3.54	3.89
7	4.07	3.57	3.22	3.53
8	3.19	3.97	4.18	3.35
9	3.44	3.60	3.75	3.57
10	3.72	3.55	3.49	3.73
Média	3.56	3.46	3.61	3.79

Com base na observação do Quadro 26, o modelo utilizado é constituído por 3 observações por folha, uma vez que, é aquele que nas dez iterações realizadas apresenta menor erro médio.

A.4

Com o objetivo de definir o número de neurónios da camada intermédia da Rede Neuronal Artificial foram utilizados o Quadro 27 e a Figura 38 que se apresentam em baixo.

Quadro 27 – Erro quadrático para os diferentes modelos de redes neuronais artificiais

	Número de Neurónios da Camada Intermédia									
	2	4	6	8	10	12	14	16	18	20
$R_{\text{fase de treino}}$	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.93
$R_{\text{fase de teste}}$	0.99	0.97	0.96	0.97	0.97	0.98	0.95	0.95	0.97	0.98
$R_{\text{médio}}$	0.96	0.95	0.95	0.96	0.95	0.96	0.95	0.95	0.95	0.95

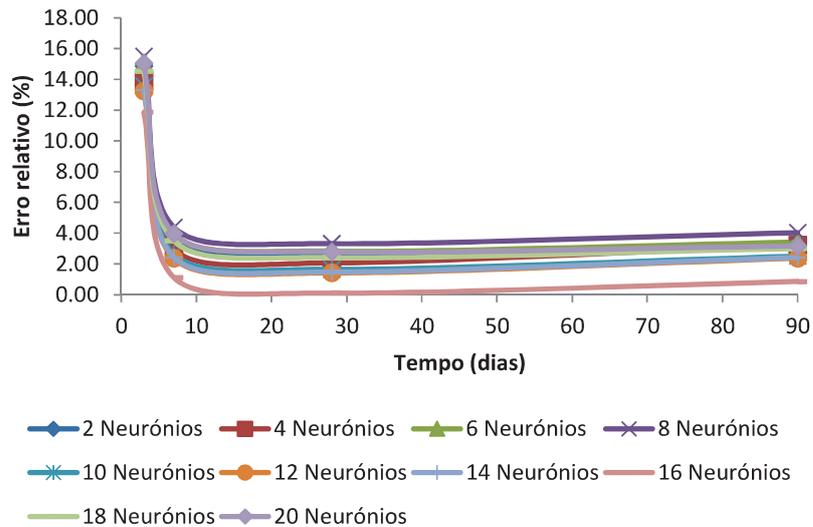


Figura 38 - Mistura B15, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais

A análise do Quadro 27 não permite obter uma resposta quanto ao número de neurónios a considerar para a camada intermédia do modelo. Deste modo, procede-se à observação da Figura 38, na qual se identifica de forma clara que o modelo constituído por 16 neurónios é o que produz melhores resultados. Assim, o modelo para o qual se apresentam os valores de resistência à compressão de provetes cilíndricos estimados é constituído por 16 neurónios.

Relativamente ao modelo k-Vizinhos Mais Próximos não foi possível obter o parâmetro k por validação cruzada, uma vez que, nas dez iterações realizadas a percentagem de erro obtida foi sempre igual a cem por cento. Assim, não foi possível concluir qual o valor de k que permitia obter o menor número de previsões erradas para a fase de teste.

Deste modo, apresenta-se em seguida o Quadro 28. No quadro, para os valores de k considerados, é indicado o erro médio referente à fração de previsões erradas por cada modelo para os dados de treino. O modelo utilizado tem parâmetro k igual a 2, uma vez que, é esse valor que apresenta menor erro médio.

Quadro 28 – Valor do erro conforme o valor de k

	Valor do parâmetro k		
	2	3	4
Erro médio (%)	45	67	79

No que concerne a definição do número de observações por folha da Árvore de Regressão foi utilizado o Quadro 29 que se apresenta em baixo. O quadro indica, para diferentes números de observações, o erro obtido para cada iteração de validação cruzada e a média do erro das dez iterações efetuadas.

Quadro 29 - Erro médio obtido por validação cruzada para diferentes números de observações por folha

Iteração	Erro absoluto (MPa) conforme o número de observações por folha				
	2	3	4	5	6
1	4.20	3.64	4.39	4.07	4.46
2	4.63	4.89	4.27	3.82	4.51
3	4.77	4.10	3.95	4.07	4.46
4	4.34	4.62	3.96	3.87	4.86
5	4.62	4.17	4.23	3.88	4.15
6	4.73	3.76	4.36	4.24	4.29
7	4.60	3.78	4.20	4.58	4.80
8	4.34	4.67	3.99	3.66	3.92
9	3.99	4.08	3.92	3.55	4.74
10	4.00	3.99	4.39	3.67	4.70
Média	4.43	4.19	4.17	3.95	4.50

Com base na análise do Quadro 29, o modelo utilizado é constituído por 5 observações por folha, uma vez que, é aquele para as dez iterações realizadas apresenta menor erro médio.

A.5

O número de neurónios da camada intermédia da Rede Neuronal Artificial foi definido através do Quadro 30 e, das Figuras 39 e 40 que se apresentam em baixo.

Quadro 30 – Erro quadrático para os diferentes modelos de redes neuronais artificiais

	Número de neurónios da camada intermédia									
	2	4	6	8	10	12	14	16	18	20
$R_{\text{fase de treino}}$	0.74	0.70	0.74	0.71	0.72	0.72	0.73	0.73	0.73	0.73
$R_{\text{fase de teste}}$	0.74	0.90	0.82	0.86	0.78	0.86	0.83	0.74	0.77	0.90
$R_{\text{médio}}$	0.74	0.80	0.78	0.79	0.75	0.79	0.78	0.73	0.75	0.82

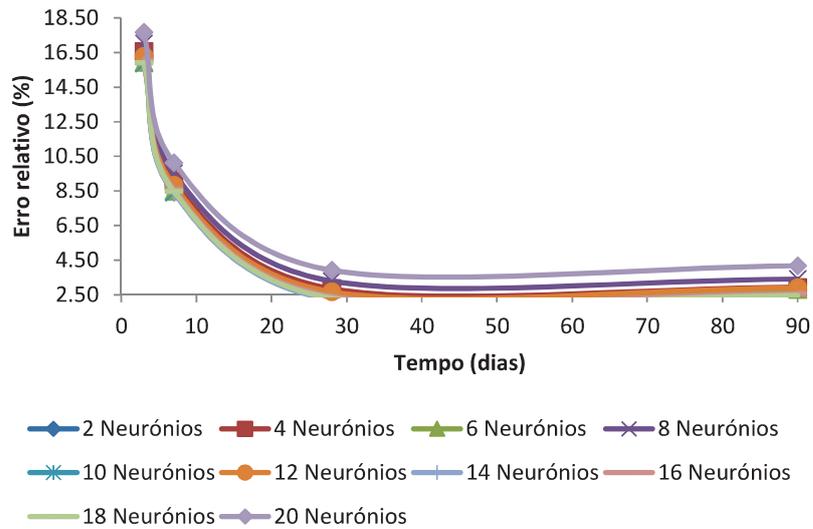


Figura 39 - Mistura B16, erro relativo conforme o instante de tempo para as diferentes redes neuronais artificiais

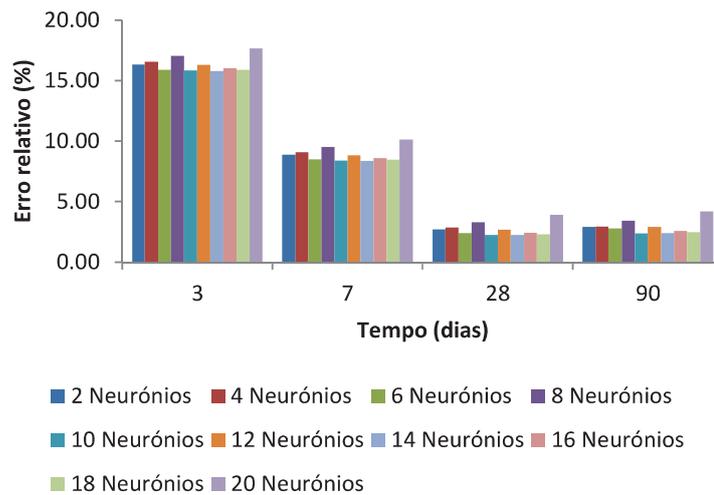


Figura 40 - Mistura B16, erro relativo ao longo do tempo para as diferentes redes neuronais artificiais

Com base na análise das Figuras 39 e 40, verifica-se que os modelos com 6, 10 e 14 neurónios são os que apresentam um menor erro relativo. Através da observação do Quadro 30 constata-se que o modelo com menor número de neurónios (seis) apresenta um valor de erro quadrático para a fase de treino idêntico ao dos modelos com maior número. Deste modo, foi considerado o modelo de 6 neurónios como sendo aquele que apresentou melhores resultados.

Relativamente ao modelo k-Vizinhos Mais Próximos não foi possível obter o parâmetro k por validação cruzada pois, nas dez iterações realizadas a percentagem de erro obtida foi sempre igual a cem por cento. Assim, não foi possível identificar o valor de k que permitia obter o menor número de previsões erradas para a fase de teste do modelo.

Assim, recorreu-se ao Quadro 31 que se apresenta em seguida. No quadro, para cada valor de k considerado, é indicado o erro médio referente à fração de previsões erradas por cada modelo para os dados de treino. O modelo utilizado tem parâmetro k igual a 2, uma vez que, é para esse valor que se observa menor erro médio.

Quadro 31 – Valor do erro conforme o valor de k

	Valor do parâmetro k		
	2	3	4
Erro médio (%)	44	66	69

No que diz respeito à definição do número de observações por folha da Árvore de Regressão foi utilizado o Quadro 32 que se apresenta em seguida. O quadro indica, para diferentes números de observações, o erro obtido para cada uma das dez iterações de validação cruzada realizadas e a média do erro referente ao número total de iterações.

Quadro 32 – Erro médio obtido por validação cruzada para diferentes números de observações por folha

Iteração	Erro absoluto (GPa) conforme o número de observações por folha				
	2	3	4	5	6
1	1.86	1.58	1.70	1.47	1.63
2	1.44	1.82	1.67	1.49	1.73
3	1.80	1.79	1.83	1.54	1.64
4	1.70	1.68	1.63	1.60	1.48
5	1.68	1.80	1.79	1.66	1.63
6	1.53	1.78	1.79	1.63	1.46
7	1.75	1.72	1.68	1.56	1.55
8	1.62	1.41	1.64	1.74	1.58
9	1.44	1.68	1.61	1.53	1.69
10	1.73	1.44	1.64	1.49	4.85
Média	1.66	1.67	1.70	1.57	1.63

O modelo utilizado é constituído por 5 observações por folha pois, é aquele que para as dez iterações realizadas apresentou menor erro médio.

A.6

Face ao limitado número de resultados de ensaios de resistência à tração ao longo do tempo e, para que fosse possível desenvolver modelos de Redes Neurais Artificiais, a base de dados utilizada na fase de treino é também constituída pelos registos da densidade e da resistência à compressão de provetes cilíndricos.

Os modelos k-Vizinhos Mais Próximos e Árvore de Regressão desenvolvidos contêm apenas os resultados dos ensaios de resistência à tração. Contrariamente aos modelos de Redes Neurais Artificiais, a modelação desses sistemas (Árvore de Regressão e k-Vizinhos Mais Próximos) é apenas possível considerando um parâmetro mecânico.

De forma a definir o número de neurónios da camada intermédia da rede neuronal artificial utilizaram-se o Quadro 33 e as Figuras 41 e 42 que se apresentam em seguida.

Quadro 33 – Erro quadrático para as diferentes redes neuronais artificiais

	Número de neurónios da camada intermédia									
	2	4	6	8	10	12	14	16	18	20
$R_{\text{fase de treino}}$	1	1	1	1	1	1	1	1	1	1
$R_{\text{fase de teste}}$	1	1	1	1	1	1	1	1	1	1
$R_{\text{médio}}$	1	1	1	1	1	1	1	1	1	1

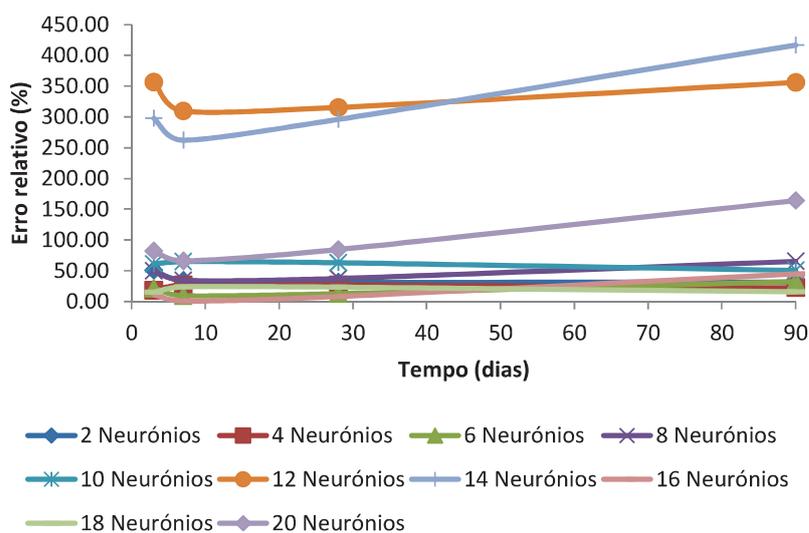


Figura 41 - Mistura B15, erro relativo conforme o instante para as diferentes redes neuronais artificiais

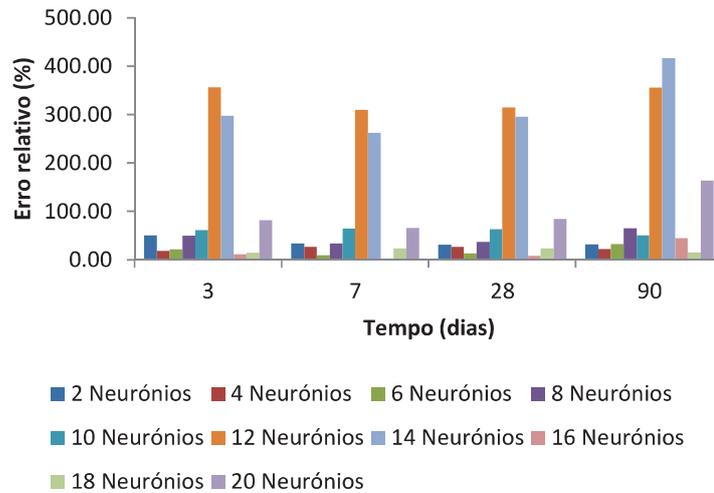


Figura 42 - Mistura B15, erro relativo conforme o instante de tempo para os modelos de redes neuronais artificiais desenvolvidos

Os modelos com menor número de neurónios que apresentam melhores resultados são os constituídos por 4 e 6 neurónios na camada intermédia (Figura 42). Como o Quadro 33 não permite obter nenhuma informação relevante para a definição do número de neurónios, foi considerado o modelo constituído por 4 neurónios como o mais adequado.

Regra geral, modelos com um menor número de neurónios apresentam melhor capacidade para generalizar pois não se encontram tão ajustados ao conjunto de dados de treino. O modelo de 4 neurónios denota um valor de erro mais homogéneo, enquanto o de 6 neurónios varia de forma mais acentuada ao longo do tempo.

Em relação ao modelo k-Vizinhos Mais Próximos não foi possível obter o parâmetro k por validação cruzada, uma vez que, para as dez iterações realizadas a percentagem de erro obtida foi sempre igual a cem por cento. Assim, não foi exequível identificar o valor de k que permitia obter o menor número de previsões erradas para a fase de teste.

Deste modo, foi utilizado o Quadro 34 que se apresenta em seguida. No quadro, para cada valor de k considerado, é indicado o erro médio referente à fração de previsões erradas por cada modelo para os dados de treino. O modelo utilizado tem parâmetro k igual a 2, uma vez que, é para esse valor que se observa menor erro médio.

Quadro 34 – Erro médio obtido por validação cruzada para cada valor de k

	Valor do parâmetro k		
	2	3	4
Erro médio (%)	57	71	71

No que diz respeito à definição do número de observações por folha da Árvore de Regressão apresenta-se em seguida o Quadro 35. O quadro indica, para diferentes números de observações, o erro obtido para cada uma das dez iterações de validação cruzada realizadas e a média do erro referente ao número total de iterações.

Quadro 35 - Erro médio obtido por validação cruzada para diferentes números de observações por folha

Iteração	Erro absoluto (MPa) conforme o número de observações por folha	
	2	3
1	0.56	0.54
2	0.50	0.57
3	0.50	0.56
4	0.50	0.57
5	0.48	0.54
6	0.54	0.51
7	0.51	0.49
8	0.48	0.50
9	0.57	0.57
10	0.51	0.54
Média	0.52	0.54

Com base na análise do Quadro 35 o modelo utilizado tem 2 observações por folha, uma vez que, esse é o número de observações que para as dez iterações realizadas apresenta menor erro médio.