

PREVISÃO DA TEMPERATURA EM SECÇÕES DE MADEIRA UTILIZANDO REDES NEURONAIAS ARTIFICIAIS

PREDICTION OF TEMPERATURE IN TIMBER CROSS-SECTIONS USING ARTIFICIAL NEURAL NETWORKS

Paulo B. Cachim ⁽¹⁾

(1) Prof., RISCO & Departamento de Engenharia Civil, Universidade de Aveiro, Aveiro, Portugal
Endereço de contato: pcachim@ua.pt

Código de identificação: T6-08

Resumo

As redes neuronais artificiais constituem uma poderosa ferramenta para modelar as propriedades e o comportamento de materiais em muitas áreas da engenharia civil. Neste artigo, apresentam-se modelos de redes neuronais artificiais utilizados para prever as temperaturas em secções de madeira sob ação de incêndio. Para a construção destes modelos, utilizaram-se os resultados de simulações numéricas das temperaturas na madeira, calculados com o método avançado definido no Eurocódigo 5. Utilizou-se uma rede neuronal de alimentação direta, com seis parâmetros de entrada (massa específica, dimensão da secção, tempo de exposição ao fogo e distâncias aos bordos). Com estes parâmetros de entrada a RNA calcula a temperatura no ponto considerado. Os treinos e testes realizados com a rede neuronal demonstraram que estas podem ser utilizadas para prever as temperaturas em secções de madeira sujeitas a incêndio.

Palavras chave: redes neuronais artificiais; temperaturas; incêndio; madeira

Abstract

Neural networks are a powerful tool used to model properties and behaviour of materials in many areas of civil engineering applications. In the present paper, the models in artificial neural networks for predicting the temperatures in timber under fire loading have been developed. For building these models, training and testing using the available numerical results obtained using design methods of Eurocode 5 have been used. The data used in the multilayer feed forward neural network models are arranged for rectangular cross-sections in a format of six input parameters that cover the density of timber, the size of the cross-section, the time of fire exposure and the distance from exposed sides. With these input parameters used in the multilayer feed forward neural network the temperatures in timber are predicted. The training and testing results in the neural network model have shown that neural networks can accurately calculate the temperature in timber members subjected to fire.

Keywords: artificial neural networks; temperatures; fire; timber

1. INTRODUÇÃO

O comportamento das estruturas de madeira em situação de incêndio é um dos problemas mais relevantes no estudo destas estruturas. O Eurocódigo 5, Parte 1-2 [1], apresenta métodos de cálculo simplificados para dimensionamento de elementos de madeira sob a ação do fogo. Contudo, os métodos simplificados apresentados apresentam inconsistências entre si e não consideram parâmetros fundamentais do comportamento como a densidade ou, nalguns casos, a natureza do esforço a que a secção está sujeita [2].

As redes neurais artificiais (RNA) têm vindo a adquirir nos últimos anos uma utilização crescente no domínio da Engenharia Civil. Os tipos de problemas às quais podem ser aplicadas são muito diversos e a variedade de aplicações tem vindo a aumentar. No domínio da Engenharia Civil as redes neurais têm vindo a ser aplicadas para a estimação de propriedades de materiais, como por exemplo a resistência do betão à compressão, abaixamento, ou módulo de elasticidade, mas também noutros domínios como a interação solo-estrutura ou a resistência de vigas ao corte [3-21]. As RNA foram também utilizadas para previsão de temperaturas em elementos de madeira com apenas uma face exposta ao fogo [22], demonstrando que a sua utilização é possível neste domínio. Contudo, o modelo apresentado em [22], por ser unidimensional, não permite a análise de elementos de madeira sujeitos ao fogo em três ou quatro faces.

O objetivo deste artigo é o de analisar a possibilidade de utilização de RNA para previsão das temperaturas em secções retangulares de madeira sujeitas à ação do fogo.

2. CÁLCULO DA TEMPERATURA NA MADEIRA

O cálculo da temperatura na madeira em situação de incêndio pode ser efetuado utilizando o modelo de cálculo avançado proposto no Eurocódigo 5, Parte 1-2 [1]. Este modelo, baseado na condutividade da madeira, utiliza a equação diferencial de transporte de calor e propriedades da madeira dependentes da temperatura. O modelo apresentado no Eurocódigo 5 apresenta algumas limitações e não considera de forma explícita efeitos como a transferência de massa no elemento, fissuração na camada carbonizada, energia de reação libertada no interior da madeira pela pirólise ou degradação do material ou o teor de água da madeira. Apesar de tudo, o modelo consegue reproduzir de forma razoável o comportamento da madeira em situação de incêndio, através da utilização de propriedades modificadas para a madeira. Assim, a condutividade térmica da madeira foi modificada para simular a fissuração a temperaturas acima dos 500 °C e o calor específico é apresentado com um pico entre os 100 e os 120 °C, correspondente à energia necessária para a evaporação da água (considerada com um teor de água na madeira de 12%). Os valores da condutibilidade térmica, calor específico e densidade em função da temperatura da madeira especificados no Eurocódigo 5 encontram-se na Figura 1 [1].

O coeficiente de transferência de calor por convecção em superfícies não expostas foi considerado igual a 9 W/m²K e em superfícies aquecidas com a curva de incêndio padrão foi considerado igual a 25 W/m²K, conforme definido no Eurocódigo 1, Part 1-2 [23]. A emissividade superficial da madeira foi considerada com o valor 0.8 [1].

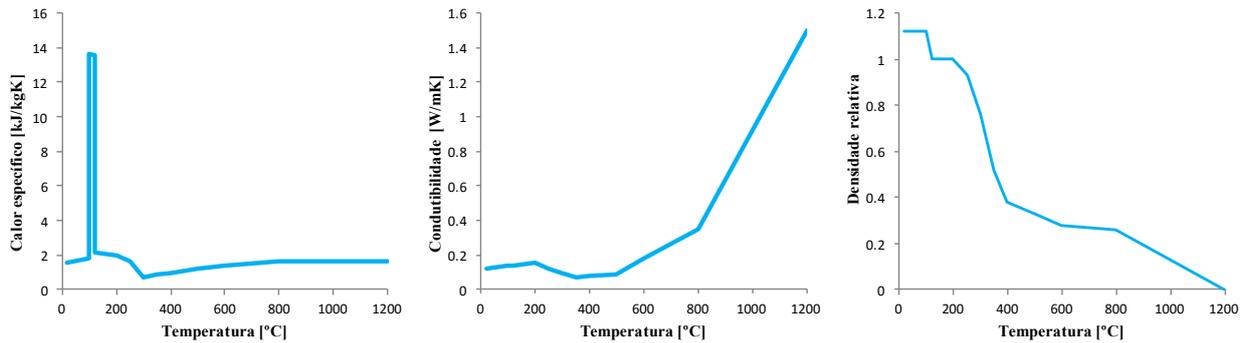


Figura 1: Propriedades térmicas da madeira

O cálculo das temperaturas na madeira foi efetuado recorrendo ao programa de elementos finitos SAFIR [24], que é um programa especialmente destinado à análise de estruturas em situação de incêndio. O programa calcula as temperaturas no interior da secção de madeira a intervalos de tempo definidos pelo utilizador. A temperatura num ponto no interior da secção é função da densidade da madeira, do tempo de exposição ao fogo, das dimensões da secção e da distância aos bordos do ponto. Sendo as propriedades mecânicas da madeira dependentes da temperatura, é possível posteriormente utilizar os valores reduzidos da resistência e rigidez da madeira, calculados em função da temperatura, para determinar o comportamento mecânico da secção ou elemento.

3. REDES NEURONAIS ARTIFICIAIS

No presente trabalho utilizaram-se redes neuronais artificiais de alimentação direta ou avante (*feedforward networks*). Numa rede neuronal de alimentação direta é os neurónios estão agrupados em camadas. Os neurónios de cada camada são independentes entre si, mas relacionam-se com todos os neurónios das camadas adjacentes. Uma rede deste tipo tem pelo menos três camadas: (i) a camada dos dados (*input layer*); (ii) a camada de saída (*output layer*); e (iii) uma camada oculta (*hidden layer*) com um determinado número de neurónios. As redes mais complexas podem ter várias camadas ocultas. A Figura 1 ilustra uma rede deste tipo onde é visível que cada neurónio de uma camada se relaciona com todos os neurónios das camadas adjacentes e que, cada neurónio não se relaciona com neurónios da mesma camada nem das camadas que não lhe são adjacentes.

O princípio de funcionamento de uma rede de alimentação direta é o seguinte: cada neurónio da camada de dados recebe informação proveniente de dados de ensaios ou modelos que representa o *output* desta camada para a camada seguinte, depois de devidamente ponderado; em cada camada subsequente, cada neurónio recebe a soma ponderada dos *outputs* da camada anterior, s_j , e, através da função de ativação, transforma-os em *inputs* da camada seguinte (ver Figura 1). É comum a soma de um viés, b_j , à soma ponderada dos *outputs*., de acordo com a equação (1):

$$s_j = b_j + \sum_{i=1}^n w_{ij} o_i \quad (1)$$

em que w_{ij} representa o peso no neurónio j de uma camada, do neurónio i da camada anterior.

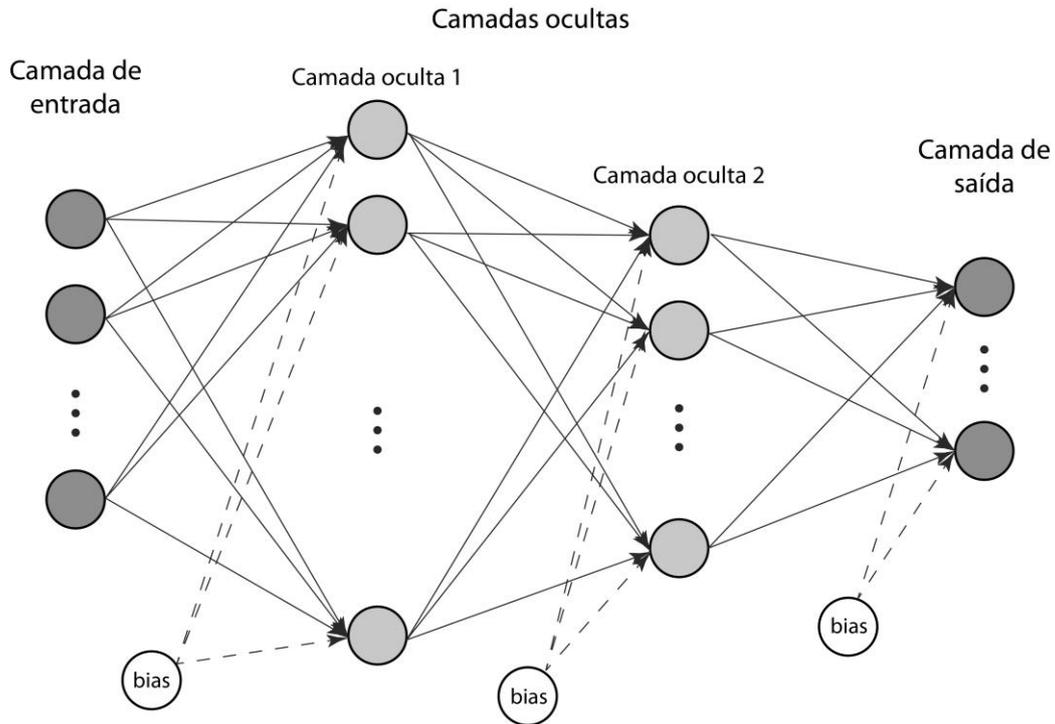


Figura 2: Esquema de uma RNA de alimentação direta

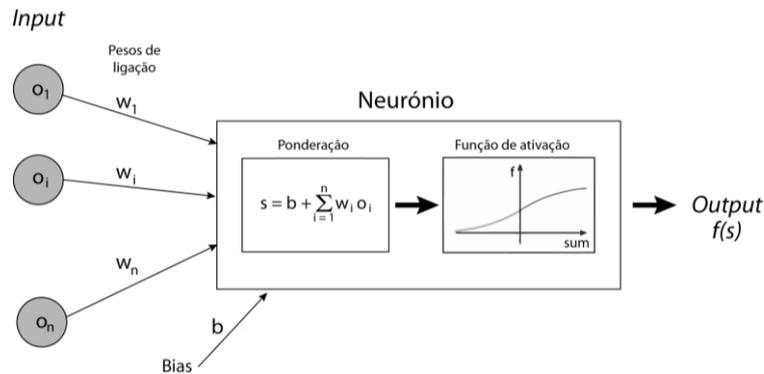


Figura 3: Esquema de cálculo de um neurónio individual

A soma ponderada dos neurónios da camada anterior (adicionada a um eventual viés), representa o *input* para cada neurónio. Este valor, é ativado através da função de ativação, f , gerando o *output* do neurónio, o_j . Existem diversas expressões comumente utilizadas para a função de ativação, sendo uma das mais correntes a função sigmoide:

$$o_j = f(s_j) = \frac{1}{1 + \exp(-\alpha s_j)} \quad (2)$$

A razão de variação da função sigmoide é controlada pelo parâmetro α , verificando-se que o crescimento da função é mais acentuado à medida que o parâmetro α aumenta. Um valor correntemente utilizado para o parâmetro é $\alpha = 2$.

Os valores dos parâmetros de entrada e saída das RNA de alimentação direta são normalizados no intervalo $[0, 1]$, sendo, por questões práticas e numéricas utilizado normalmente o intervalo $[0.1, 0.9]$.

3.1 Definição e treino da rede

Não existe nenhum método fiável para a determinação do número de camadas ocultas e do número de neurónios em cada camada. Assim, a determinação destes parâmetros tem de ser realizada por tentativas, procurando a configuração da rede que dê melhores resultados. Quanto maior for o número de parâmetros de entrada e saída do problema, maior será, em geral, o número de camadas e de neurónios por camada necessários.

O algoritmo de aprendizagem utilizado foi a retro propagação (*back propagation*) que é um dos mais utilizados no treino de redes multicamada. É uma técnica de gradiente descendente para minimizar o erro de um determinado padrão, ajustando os pesos de uma pequena quantidade em cada iteração. O erro da rede é passado da camada de resultados para as camadas anteriores, até à camada de entrada. Os pesos são ajustados com base em estratégias de aprendizagem de forma a reduzir o erro final.

3.2 Teste da qualidade e resultados da rede

Após o processo de aprendizagem e treino da RNA, os outputs podem ser calculados para qualquer conjunto de dados de entrada utilizando um algoritmo como representado em pseudo-código na Figura 4. Neste, as camadas são numeradas de 0 até *nlayer*, com a camada 0 a corresponder à camada de entrada e *nlayer* à camada de saída. Os *outputs* da camada 0 são os valores de entrada na rede e são guardados no vetor *output[0]*, enquanto os *outputs* são guardados no vetor *output[nlayer]*.

```

for ilayer=1 to nlayer
  for in=1 to nneuron[ilayer]
    // calcular o peso de ativação
    sum[in] = bias[ilayer][in]
    for jn=1 to nneuron[ilayer-1]
      sum[in] += weight[ilayer][in][jn]*output[ilayer-1][jn]
    next jn
    // calcular output utilizando a função de ativação
    output[ilayer][in] = ActivationFunction( sum[in] )
  next in
next ilayer

```

Figura 4: Pseudo-código para cálculo de *outputs* numa RNA

Para validar o desempenho da rede neuronal, considerou-se, de todos os dados e resultados disponíveis, um subconjunto para treinar a rede e os restantes para validar a rede neuronal. Para o treino da rede, os resultados numéricos das temperaturas são utilizados como *outputs* e a diferença dos valores obtidos pela RNA para estes é utilizada para medir o erro. Este erro, que ocorre durante o treino e o teste da rede neuronal, pode ser calculado com diversas medidas de erro, sendo usualmente utilizadas a Raiz do Erro Quadrático Médio (RMSE) e o Erro Absoluto Médio (MAE) que podem ser calculados utilizando as equações (3) e (4), respetivamente:

$$RMSE = \sqrt{\frac{1}{p} \sum_{i=1}^p (t_i - o_i)^2} \quad (3)$$

$$MAE = \frac{1}{p} \sum_{i=1}^p |t_i - o_i| \quad (4)$$

em que t_i é o resultado esperado (no caso presente, o valor obtido pela análise numérica), o_i é o resultado previsto (calculado pela rede) e p é o número de pontos nos quais as temperaturas foram calculadas.

Para além das medidas de erro anteriores, a precisão das previsões foi também calculada recorrendo ao Coeficiente de Distribuição (R^2) e ao erro de percentagem médio absoluto (MAPE) calculado de acordo com as equações (5) e (6), respetivamente. Na equação (5), t^* representa a média dos resultados esperados.

$$R^2 = 1 - \frac{\sum_{i=1}^p (t_i - o_i)^2}{\sum_{i=1}^p (t_i - \bar{t})^2} \quad (5)$$

$$MAPE = \frac{1}{p} \sum_{i=1}^p \left| \frac{t_i - o_i}{t_i} \right| \quad (6)$$

4. APLICAÇÃO DAS REDES NEURONAS ARTIFICIAIS À MADEIRA

4.1 Cálculo numérico das temperaturas na madeira

Devido à inexistência de dados experimentais de temperaturas em elementos de madeira que permitissem alimentar a rede neuronal, recorreu-se à utilização do cálculo numérico para obtenção das temperaturas. Para o cálculo das temperaturas utilizaram-se 13 secções transversais com dimensões entre os 120x120 mm² e os 300x300 mm², de acordo com a Tabela 1. Na discretização da malha de elementos finitos foram utilizados elementos com dimensões que variaram dos 3x3 mm² aos 5x5 mm². Esta dimensão permite uma caracterização adequada do campo de temperaturas no interior da secção transversal. Foram utilizadas madeiras com densidades de 350, 450, 600 e 800 kg/m³. O registo das temperaturas foi realizado a cada 300 segundos durante uma hora (3600 segundos).

Tabela 1: Secções de madeira analisadas

Dimensão x (mm)	Dimensão y (mm)						
	120	150	180	210	240	270	300
120	x		x		x		x
150		x					
180			x		x		x
210				x			
240					x		x
270						x	
300							x

As secções foram sujeitas à ação de incêndio, segundo a curva ISO 834, em todas as quatro faces. Devido à simetria das secções, foi analisado apenas 1/4 da secção transversal.

4.2 Previsão das temperaturas na madeira usando uma RNA

Para a definição de uma RNA que fosse capaz de modelar as temperaturas, escolheu-se uma rede neuronal artificial de alimentação direta com duas camadas ocultas (depois de se verificar que com

apenas uma camada oculta os resultados não eram satisfatórios). Foram testadas diversas conjugações de neurónios em cada uma das camadas ocultas, conforme a Tabela 2.

A RNA possui seis neurónios na camada de entrada e um na camada de saída. Na camada de entrada os neurónios são a densidade da madeira, a dimensão x da secção, a dimensão y da secção, o tempo de exposição ao fogo, a distância x ao bordo lateral e a distância y ao bordo inferior. O neurónio de saída é a temperatura.

Tabela 2: Configurações de RNA utilizadas no treino

Nº treino (40% dos pontos)	Nº Neurónios		Nº de Iterações	<i>Erro</i>
	1ª camada	2ª camada		
1	21	20	300000	0,2604
2	19	18	300000	0,2402
3	18	17	300000	0,1830
4	19	16	300000	0,4681
5	17	16	300000	0,1796
6	15	14	300000	0,4479
7	16	15	300000	0,3997
8	17	17	300000	0,4259

Das análises numéricas realizadas resultaram 82734 pontos com temperaturas. Para treinar a RNA utilizaram-se 40% destes pontos escolhidos aleatoriamente, o que perfaz um total de 32950 pontos para o treino da rede.

Das diferentes configurações da rede utilizadas, verificou-se, conforme se observa na Tabela 2, que a configuração mais eficiente tem 17 neurónios na primeira camada oculta e 16 na segunda. A Tabela 3 apresenta diversas medidas de erro, conforma definidas pelas equações (3) a (6). Em termos de temperatura o erro médio varia entre os 2,4 e os 3,6 °C, dependendo da medida utilizada, enquanto em termos de percentagem, o erro médio se situa nos 2,84%, o que constitui um valor bastante aceitável.

Tabela 3: Erros obtidos após o treino da RNA

RMSE (°C)	MAE (°C)	MAPE %	R ²
3,608	2,405	2,841	0,99994

Em termos gráficos, a Figura 5 ilustra a comparação entre as temperaturas calculadas com o SAFIR (em abcissa) com as obtidas pela RNA (em ordenada). É possível observar que a previsão é bastante boa ao longo de toda a gama de temperaturas analisada.

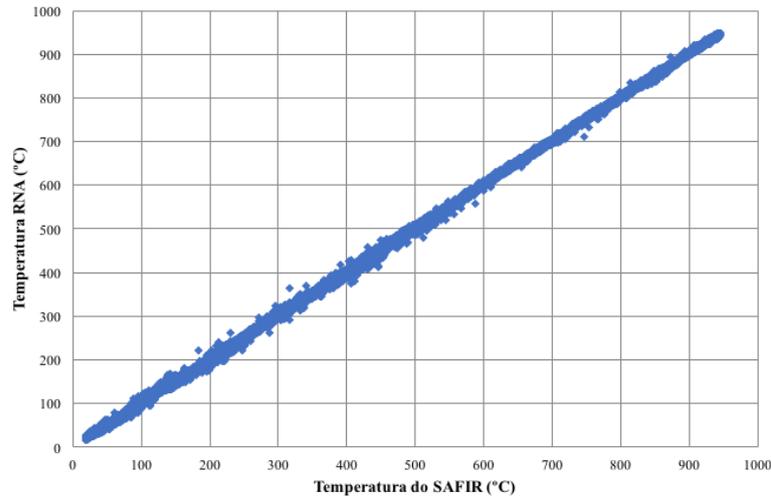


Figura 5: Comparação das temperaturas no SAFIR e na RNA após o treino da rede

Para testar a RNA, utilizaram-se a totalidade dos pontos calculados com o SAFIR. A comparação gráfica dos resultados da RNA com o SAFIR está representada na Figura 6. Verifica-se igualmente uma boa concordância, embora com uma maior dispersão dos resultados.

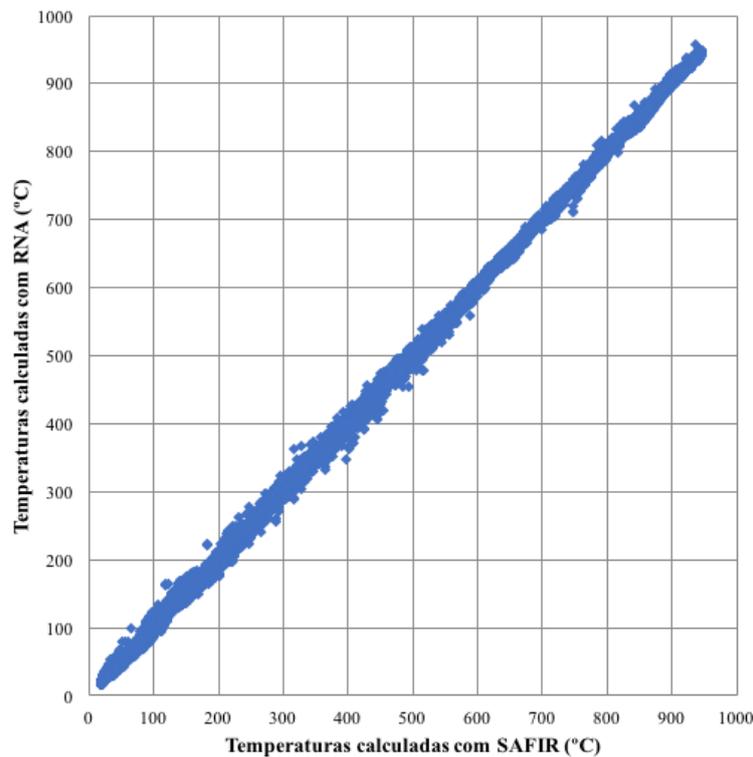


Figura 6: Aplicação do cálculo da RNA a todos os pontos

No que se refere às medidas de erro, apresentadas na Tabela 4, observa-se um ligeiro aumento face aos valores da Tabela 3, mas continuam a mostrar um bom desempenho da RNA. O erro médio em termos de temperatura varia entre os 2,4 e os 3,7 °C, enquanto o erro percentual médio se situa nos 3,0%, valores ligeiramente acima dos anteriores.

Tabela 4: Erros obtidos após o teste da RNA

RMSE (°C)	MAE (°C)	MAPE %	R ²
3,681	2,426	3,014	0,99989

Apresentam-se na Figura 7 dois cortes horizontais com as temperaturas ao longo da secção, onde se comparam mais uma vez os resultados do SAFIR com os da RNA, para o caso de madeira com massa específica de 450 kg/m³ e dimensão 120x240 mm², ao fim de 30 minutos. Nos dois casos, localizados a 80 e a 120 mm da face inferior, observa-se uma excelente previsão das temperaturas por parte da RNA, não sendo observáveis praticamente diferenças entre as curvas.

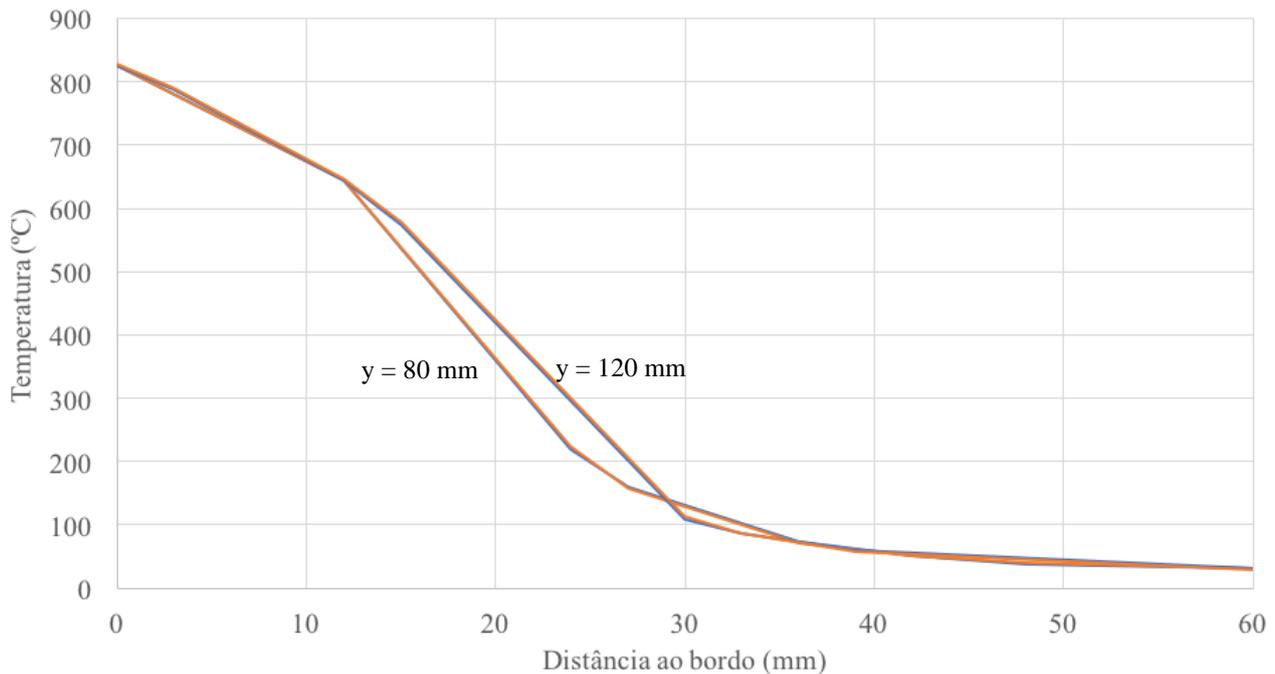


Figura 7: Cortes transversais, 450 kg/m³, 120x240 mm²

5. CONCLUSÕES

As redes neurais artificiais são uma ferramenta capaz de resolver problemas complexos em diversas áreas da engenharia. Neste estudo, foram utilizadas redes neurais artificiais de alimentação direta para previsão das temperaturas em secções retangulares de madeira, sujeitas a ação de incêndio padrão.

Os resultados foram validados para madeiras com densidade entre 350 e 800 kg/m³, dimensões da secção entre 100x100 e 300x300 mm² e tempos de exposição ao fogo até 60 minutos, segundo os modelos do Eurocódigo 5.

A utilização das redes neurais artificiais permite que os projetistas consigam, com um muito menor esforço computacional, determinar as temperaturas de secções retangulares expostas a incêndio, com a qualidade do método avançado de cálculo definido no Eurocódigo 5. As temperaturas assim calculadas podem posteriormente ser utilizadas nos modelos mecânicos, de forma a determinar o comportamento mecânico da secção em causa.

AGRADECIMENTOS

O autor gostaria de agradecer à Universidade de Aveiro, FCT/MEC pelo apoio financeiro à Unidade de Investigação RISCO (FCT/UID/ECI/04450/2013).

REFERÊNCIAS

- [1] CEN, EN 1995-1-2:2004: Eurocode 5: Design of timber structures - Part 1-2: General - Structural fire design, CEN, Editor. 2004: Brussels, Belgium.
- [2] CACHIM, P. and J. FRANSSEN, Comparison between the charring rate model and the conductive model of Eurocode 5. FIRE AND MATERIALS, 2009. **33**(3): p. 129-143.
- [3] Topçu, I.B., C. Karakurt, and M. Sarıdemir, Predicting the strength development of cements produced with different pozzolans by neural network and fuzzy logic. Materials & Design, 2008. **29**(10): p. 1986-1991.
- [4] Sarıdemir, M., Predicting the compressive strength of mortars containing metakaolin by artificial neural networks and fuzzy logic. Advances in Engineering Software, 2009. **40**(9): p. 920-927.
- [5] Sarıdemir, M., Prediction of compressive strength of concretes containing metakaolin and silica fume by artificial neural networks. Advances in Engineering Software, 2009. **40**(5): p. 350-355.
- [6] Ashu, J., J. Sanjeev Kumar, and M. Sudhir, Modeling and Analysis of Concrete Slump Using Artificial Neural Networks. Journal of Materials in Civil Engineering, 2008. **20**(9): p. 628-633.
- [7] Dias, W.P.S. and S.P. Pooliyadda, Neural networks for predicting properties of concretes with admixtures. Construction and Building Materials, 2001. **15**(7): p. 371-379.
- [8] Adhikary, B.B. and H. Mutsuyoshi, Prediction of shear strength of steel fiber RC beams using neural networks. Construction and Building Materials, 2006. **20**(9): p. 801-811.
- [9] Alshihri, M.M., A.M. Azmy, and M.S. El-Bisy, Neural networks for predicting compressive strength of structural light weight concrete. Construction and Building Materials, 2009. **23**(6): p. 2214-2219.
- [10] Altun, F., Ö. Kisi, and K. Aydin, Predicting the compressive strength of steel fiber added lightweight concrete using neural network. Computational Materials Science, 2008. **42**(2): p. 259-265.
- [11] Bai, J., et al., Using neural networks to predict workability of concrete incorporating metakaolin and fly ash. Advances in Engineering Software, 2003. **34**(11-12): p. 663-669.
- [12] Bilim, C., et al., Predicting the compressive strength of ground granulated blast furnace slag concrete using artificial neural network. Advances in Engineering Software, 2009. **40**(5): p. 334-340.
- [13] Demir, F., Prediction of elastic modulus of normal and high strength concrete by artificial neural networks. Construction and Building Materials, 2008. **22**(7): p. 1428-1435.
- [14] Flood, I., Towards the next generation of artificial neural networks for civil engineering. Advanced Engineering Informatics, 2008. **22**(1): p. 4-14.
- [15] Ghaboussi, J., J.H. Garrett Jr, and X. Wu, Knowledge-Based Modeling of Material Behavior with Neural Networks. Journal of Engineering Mechanics, 1991. **117**(1): p. 132-153.
- [16] Kim, J.-I., et al., Application of Neural Networks for Estimation of Concrete Strength. Journal of Materials in Civil Engineering, 2004. **16**(3): p. 257-264.
- [17] Lai, S. and M. Serra, Concrete strength prediction by means of neural network. Construction and Building Materials, 1997. **11**(2): p. 93-98.
- [18] Öztas, A., et al., Predicting the compressive strength and slump of high strength concrete using neural network. Construction and Building Materials, 2006. **20**(9): p. 769-775.
- [19] Pala, M., et al., Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural networks. Construction and Building Materials, 2007. **21**(2): p. 384-394.
- [20] Pala, M., et al., Dynamic soil-structure interaction analysis of buildings by neural networks. Construction and Building Materials, 2008. **22**(3): p. 330-342.
- [21] Parichatprecha, R. and P. Nimityongskul, Analysis of durability of high performance concrete using artificial neural networks. Construction and Building Materials, 2009. **23**(2): p. 910-917.
- [22] Cachim, P., V. Kodur, and J. Franssen, Using Artificial Neural Networks for Predicting Temperatures in Timber. Structures in Fire: Proceedings of the 6th International Conference, 2010: p. 602-610.
- [23] CEN, EN 1991-1-2:2002. Eurocode 1: Actions on structures - Part 1-2: General actions - Actions on structures exposed to fire, CEN, Editor. 2002: Brussels, Belgium.
- [24] Franssen, J.-M., SAFIR. A Thermal/Structural Program Modelling Structures under Fire. Engineering Journal, 2005. **42**(3): p. 143-158.