

## **ADEQUABILIDADE DE DIFERENTES ARQUITETURAS DE REDE NEURAL ARTIFICIAL APLICADAS A PREDIÇÃO DA RESISTÊNCIA DO CONCRETO**

**MARCELO BAHUTI<sup>1</sup>, BRUNA CAMPOS AMARAL<sup>2</sup>, RÔMULO MARÇAL GANDIA<sup>3</sup>, MURILO SANTOS FREIRE<sup>3</sup>**

<sup>1</sup> Doutorando em Engenharia Agrícola, Depto. de Engenharia Agrícola, UFLA, [marcelo\\_bahuti@hotmail.com](mailto:marcelo_bahuti@hotmail.com)

<sup>2</sup> Graduanda em Engenharia Agrícola, Depto. de Engenharia Agrícola, Universidade Federal de Lavras (UFLA).

<sup>3</sup> Doutorando em Engenharia Agrícola, Depto. de Engenharia Agrícola, Universidade Federal de Lavras (UFLA).

Apresentado no  
L Congresso Brasileiro de Engenharia Agrícola - CONBEA 2021  
08 a 10 de novembro de 2021 - Congresso On-line

**RESUMO:** O concreto é um composto de diferentes materiais que possuem propriedades e funções distintas quando empregados na mistura. Tal fato, torna a tarefa de dosagem e determinação da resistência complexas, a ponto de serem necessárias técnicas para o auxílio a tomada de decisão quanto a otimização do seu uso. As Redes Neurais Artificiais (RNA) são ferramentas que possuem a capacidade de generalização e aprendizado a partir de experiências anteriores. Desse modo, o presente trabalho teve como objetivo a implementação de diferentes arquiteturas de RNA aplicadas a determinação da resistência à compressão do concreto, quando confeccionado com diferentes traços e ensaiados em idades distintas. Os dados de entrada dos modelos foram as quantidades dos materiais, e a saída predita foi a resistência à compressão. Os resultados obtidos demonstraram que, para os dados em questão, o uso de neurônios na segunda camada oculta pode não surtir efeito significativo sobre o desempenho dos modelos, enquanto o aumento do número de neurônios na primeira camada promoveu aumento da acurácia. No entanto, é recomendado analisar, além dos indicadores estatísticos de erro (como o erro médio quadrático (MSE)), o tempo de processamento das arquiteturas, a fim de selecionar o modelo com menor demanda computacional.

**PALAVRAS-CHAVE:** modelagem do traço concreto; resistência à compressão; redes neurais artificiais.

## **SUITABILITY OF DIFFERENT ARTIFICIAL NEURAL NETWORK ARCHITECTURES APPLIED TO PREDICTING CONCRETE STRENGTH**

**ABSTRACT:** Concrete is a composite of different materials that have diverse properties and functions when used in the mix. This fact makes the task of dosage and determination of resistance complex, to the point that techniques are needed to aid decision-making regarding the optimization of its use. Artificial Neural Networks (ANN) are tools that have the ability to generalize and learn from previous experiences. Thus, the present work aimed to implement different ANN architectures applied to the determination of the compressive strength of concrete, when made with different traits and tested at different ages. The input data for the models was material quantities, and the predicted output was compressive strength. The results obtained showed that, for the data in question, the use of neurons in the second hidden layer may not have a significant effect on the performance of the models, while the increase in the number of neurons in the first layer promoted an increase in accuracy. However, it is recommended to analyze, in addition to statistical error indicators (such as mean square error

(MSE)), the processing time of the architectures, in order to select the model with the least computational demand.

**KEYWORDS:** modeling of concrete mix; compressive strength; artificial neural networks.

**INTRODUÇÃO:** O concreto tem como característica a heterogeneidade devido ao fato de ser composto pela união de diversos componentes. Nesse aspecto, quanto maior o conhecimento sobre a relação entre composição de materiais da mistura versus resistência, melhor a capacidade de otimizar o seu uso e reduzir o custo. Desse modo, a durabilidade e resistência do concreto são fatores fundamentais, tendo em vista que dependem da mistura dos componentes, da consistência e do tempo de cura. Por se tratar de uma relação complexa, a fim de melhorar o entendimento sobre o comportamento da mistura e otimizar os custos e sua aplicabilidade, faz-se necessário o uso de técnicas computacionais para auxílio à tomada de decisão. Assim, dentre os métodos numéricos existentes de processamento de dados, tem-se as Redes Neurais Artificiais (RNAs), que se apresenta como um método proposto para solucionar problemas de engenharia como, determinar a correlação entre a resistência à compressão do concreto (GETAHUN et al., 2018). Os principais benefícios em usar uma abordagem de rede neural são que todo o comportamento de um material pode ser representado dentro do ambiente unificado de uma rede neural, e o modelo baseado em RNA é construído diretamente a partir de dados experimentais usando os recursos de aprendizagem do sistema (YEH, 1998). No entanto, a RNA deve ser projetada e treinada adequadamente com dados sobre o problema para atingir a tarefa necessária (GETAHUN et al., 2018). Portanto, o objetivo do presente trabalho é verificar vários modelos, com diferentes arquiteturas, e chegar em uma rede neural artificial que seja capaz de prever a resistência à compressão do concreto com o menor erro possível.

**MATERIAL E MÉTODOS:** O banco de dados utilizado para elaboração das redes, refere-se a diferentes traços de concreto de alto desempenho, obtidos no Repositório de Aprendizado de Máquina da UC Irvine. Desse modo, para a elaboração da RNA, o conjunto de dados foi formado por 8 variáveis de entrada: quantidades de cimento ( $\text{kg m}^{-3}$ ), escória de alto forno ( $\text{kg m}^{-3}$ ), cinzas volantes ( $\text{kg m}^{-3}$ ), água ( $\text{kg m}^{-3}$ ), superplastificante ( $\text{kg m}^{-3}$ ), agregado grosso ( $\text{kg m}^{-3}$ ) e agregado fino ( $\text{kg m}^{-3}$ ), além da idade dos corpos de prova (dias). Para desenvolver os modelos baseados em RNA foi utilizado o software Matlab® (R2017a). Devido as diferenças significantes de magnitudes das variáveis de entrada, o processo de treinamento pode ser ineficiente, uma vez que esta variação pode superar tendências importantes no conjunto de dados (BISHOP 1995; ANINIAN & ANINIAN, 2000). Assim, as variáveis foram normalizadas entre 0 e 1. A fim de prever a resistência à compressão do concreto (MPa), foram confeccionadas redes com três camadas *feedforward* (input, camada oculta e camada de saída) de modo que foram empregados treinamento supervisionado com o algoritmo Levenberg-Marquardt *backpropagation*, que é considerado o método mais rápido para a formação das redes (FERRAZ et al., 2019). Foi utilizado o conjunto total baseado em 1030 pares de dados. Os dados foram divididos aleatoriamente, sendo que 70% (720 dados) foram usados para treinamento, 15% (155 dados) validação e 15% (155 dados) para testes. Estas percentagens dos subconjuntos foram escolhidas, pois são as mais comuns para a modelagem matemática de sistemas (ABREU et al., 2020; HERNÁNDEZ-JULIO et al., 2014). Os parâmetros de rede iniciais foram configurados como segue: número máximo de épocas (1000), taxa de aprendizagem (0,7), e taxa de momento ( $1 \times 10^{-3}$ ). Quanto ao critério de parada da rede, utilizaram-se das 100 épocas de treinamento ou quando o valor do erro quadrático médio (MSE) atingisse zero. Foram utilizadas as funções de transferência tangente-sigmóide e linear, para as camadas ocultas e de saída, respectivamente. Com base nesses parâmetros,

desenvolveu-se 99 modelos de RNA provenientes da combinação dos diferentes números de camadas ocultas e/ou número de neurônios em cada camada (a primeira camada variou de 2 a 10 e a segunda de 0 a 11 neurônios, resultando em 99 modelos). Além do mais, cada um dos 99 modelos foi processado 100 vezes, com o intuito de encontrar tanto a melhor configuração quanto a melhor rede. Pois, os dados de entrada para treinamento e testes foram apresentados à rede neural de forma aleatória. Sendo assim, todas as vezes que a rede neural é colocada para treinamento e teste, utiliza-se um conjunto de dados diferentes. Partindo-se desse raciocínio, a rede foi treinada e testada por 100 vezes, possibilitando obter valores de MSE para cada configuração de rede. Desse modo, foram selecionadas as configurações com os maiores coeficientes de determinação ( $R^2$ ) e o menor MSE (FERRAZ et al., 2014). Ademais, com o auxílio do software SISVAR 5.7, as médias de MSE de cada configuração foram submetidas à análise de variância e tiveram médias comparadas pelo teste Scott Knott, ao nível de 5% de significância, a fim de encontrar a configuração de menor demanda computacional.

**RESULTADOS E DISCUSSÃO:** Não existem diretrizes precisas e claras para determinação da arquitetura, que geralmente é escolhida com base na experiência do projetista da rede ou por tentativa e erro (TAVARES et al., 2020). A Tabela 1 lista as 99 configurações, na qual é possível observar que as diferenças das arquiteturas das redes se deram apenas pelo número de neurônios nas camadas ocultas. Por sua vez, a Tabela 2 lista as médias e desvios padrões para as 100 repetições de cada um dos respectivos modelos listados na Tabela 1. A partir dos valores médios MSE foi observada diferença estatística entre os modelos ( $p < 0,05$ , teste F). Desse modo, a configuração que obteve o melhor resultado foi o modelo 93 (10 neurônios na primeira camada e 4 neurônios na segunda camada), no qual obteve MSE de  $1,53 \times 10^{-4} \pm 3,2 \times 10^{-5}$  MPa. Getahun et al. (2018), ao desenvolverem uma RNA para prever a resistência do concreto incorporado com resíduos, obtiveram MSE médio de 0,42 MPa, sendo esse resultado considerado pelos autores como alta precisão. Portanto, pode-se dizer que todos os 99 modelos obtiveram desempenho satisfatório. Ao analisar as variações do número de neurônios da primeira camada (N1), dentro do número de neurônios na segunda camada (N2), observa-se que o aumento de N1 promove melhora no desempenho dos modelos, independentemente da quantidade de N2 (com exceção para os modelos 56, 58, 72 e 75). Por outro lado, quando analisada a variação de N2 dentro de N1, observa-se que para menores (2 e 3) e maiores (8, 9 e 10) valores de N1, o aumento de N2 não promove melhora no desempenho dos modelos, não sendo justificável a implementação da segunda camada oculta, pois tal recurso geraria apenas maior demanda computacional para o processamento da rede.

TABELA 1. Identificação numérica dos 99 modelos gerados de acordo com o número de neurônios em cada camada oculta.

		Identificação do modelo									
Nº neurônios na primeira camada	Nº neurônios na segunda camada										
	0	1	2	3	4	5	6	7	8	9	10
2	1	2	3	4	5	6	7	8	9	10	11
3	12	13	14	15	16	17	18	19	20	21	22
4	23	24	25	26	27	28	29	30	31	32	33
5	34	35	36	37	38	39	40	41	42	43	44
6	45	46	47	48	49	50	51	52	53	54	55
7	56	57	58	59	60	61	62	63	64	65	66
8	67	68	69	70	71	72	73	74	75	76	77
9	78	79	80	81	82	83	84	85	86	87	88
10	89	90	91	92	93	94	95	96	97	98	99

TABELA 2. Erro quadrático médio ( $10^{-4}$ ) para as 99 configurações testadas com diferentes quantidades de neurônios nas camadas ocultas.

Nº neurônios na primeira camada (N1)	Nº neurônios na segunda camada (N2)										
	0	1	2	3	4	5	6	7	8	9	10
2	2,18 <sup>D</sup>	2,17 <sup>D</sup>	2,30 <sup>D</sup>	2,18 <sup>D</sup>	2,19 <sup>D</sup>	2,29 <sup>D</sup>	2,20 <sup>D</sup>	2,20 <sup>D</sup>	2,15 <sup>D</sup>	2,18 <sup>D</sup>	2,20 <sup>D</sup>
3	2,04 <sup>C</sup>	1,96 <sup>C</sup>	2,01 <sup>C</sup>	1,88 <sup>C</sup>	1,93 <sup>C</sup>	1,89 <sup>C</sup>	1,92 <sup>C</sup>	1,86 <sup>C</sup>	1,98 <sup>C</sup>	1,90 <sup>C</sup>	1,91 <sup>C</sup>
4	1,94 <sup>C</sup>	1,92 <sup>C</sup>	1,89 <sup>C</sup>	1,86 <sup>C</sup>	1,97 <sup>C</sup>	1,78 <sup>B</sup>	1,84 <sup>B</sup>	1,82 <sup>B</sup>	1,89 <sup>C</sup>	1,80 <sup>B</sup>	1,75 <sup>B</sup>
5	1,84 <sup>B</sup>	1,79 <sup>B</sup>	1,78 <sup>B</sup>	1,74 <sup>B</sup>	1,76 <sup>B</sup>	1,72 <sup>B</sup>	1,74 <sup>B</sup>	1,68 <sup>A</sup>	1,70 <sup>B</sup>	1,70 <sup>B</sup>	1,70 <sup>B</sup>
6	1,78 <sup>B</sup>	1,72 <sup>B</sup>	1,74 <sup>B</sup>	1,73 <sup>B</sup>	1,71 <sup>B</sup>	1,63 <sup>A</sup>	1,68 <sup>A</sup>	1,67 <sup>A</sup>	1,76 <sup>A</sup>	1,65 <sup>A</sup>	1,69 <sup>B</sup>
7	1,93 <sup>C</sup>	1,74 <sup>B</sup>	1,86 <sup>C</sup>	1,70 <sup>B</sup>	1,66 <sup>A</sup>	1,63 <sup>A</sup>	1,63 <sup>A</sup>	1,66 <sup>A</sup>	1,66 <sup>A</sup>	1,63 <sup>A</sup>	1,59 <sup>A</sup>
8	1,66 <sup>A</sup>	1,66 <sup>A</sup>	1,62 <sup>A</sup>	1,64 <sup>A</sup>	1,62 <sup>A</sup>	1,69 <sup>B</sup>	1,63 <sup>A</sup>	1,63 <sup>A</sup>	1,76 <sup>B</sup>	1,59 <sup>A</sup>	1,64 <sup>A</sup>
9	1,58 <sup>A</sup>	1,66 <sup>A</sup>	1,61 <sup>A</sup>	1,63 <sup>A</sup>	1,61 <sup>A</sup>	1,61 <sup>A</sup>	1,60 <sup>A</sup>	1,57 <sup>A</sup>	1,61 <sup>A</sup>	1,61 <sup>A</sup>	1,57 <sup>A</sup>
10	1,65 <sup>A</sup>	1,62 <sup>A</sup>	1,59 <sup>A</sup>	1,54 <sup>A</sup>	1,53 <sup>A</sup>	1,63 <sup>A</sup>	1,59 <sup>A</sup>	1,57 <sup>A</sup>	1,58 <sup>A</sup>	1,54 <sup>A</sup>	1,61 <sup>A</sup>

Médias seguidas de letras distintas, independentemente de linhas ou colunas, indicam diferença estatística ( $p < 0,05$ ) pelo teste de Scott Knott.

**CONCLUSÕES:** Para os dados em questão, a melhor arquitetura foi composta por 10 e 4 neurônios na primeira e segunda camadas ocultas, respectivamente (modelo 93). No entanto, recomenda-se avaliar o tempo de processamento de várias repetições das diferentes arquiteturas, a fim de embasar a tomada de decisão para o modelo de menor demanda computacional. Pois, para os dados em questão, o modelo 67 (8 neurônios na primeira camada e 0 na segunda) obteve resultado semelhante ao modelo 93 e com menor tempo de processamento.

#### REFERÊNCIAS:

- ABREU, L. H. P. et al. Artificial neural networks for prediction of physiological and productive variables of broilers. **Engenharia Agrícola**, v. 40, n. 1, p. 1-9, 2020.
- AMINIAN, Mehran; AMINIAN, Farzan. Neural-network based analog-circuit fault diagnosis using wavelet transform as preprocessor. **IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing**, v. 47, n. 2, p. 151-156, 2000.
- BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Clarendon, 1995; 504 p.
- FERRAZ, P. F. P.; YANAGI JUNIOR, T.; HERNÁNDEZ-JULIO, Y. F. et al. Predicting chick body mass by artificial intelligence-based models. **Pesquisa Agropecuária Brasileira**, v. 49, n. 7, p. 559-568, 2014.
- FERRAZ, G. A. S.; CECCHIN, D., FERRAZ, P. F. P et al. Redes neuronales artificiales para la predicción de la masa corporal de pollos. **Tecnología en Marcha**, v. 32, n. 2, p. 93-99, 2019.
- GETAHUN, M. A.; Shitote, S. M.; Gariy, Z. C. A et al. Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes. **Construction and Building Materials**, v. 190, p. 517-525, 2018.
- HERNÁNDEZ-JULIO, Y. F.; YANAGI JUNIOR, T.; FÁTIMA, A. P. M. et al. Models for prediction of physiological responses of Holstein dairy cows. **Applied Artificial Intelligence**, v. 28, n. 8, p. 766-792, 2014.
- TAVARES, D. S.; RIBEIRO, D. A. YANAGI JUNIOR, T. et al. Use of artificial neural networks to predict concrete compression strength. **Brazilian Journal of Development**, v. 6, p. 42815-42826, 2020.
- YE, H. I.-C. Modeling of strength of high-performance concrete using artificial neural networks. **Cement and Concrete research**, v. 28, n. 12, p. 1797-1808, 1998.