

Modelagem preditiva de propriedades mecânicas em concretos reforçados com fibra de aço utilizando redes neurais artificiais

Predictive modeling of the mechanical properties of concrete reinforced with steel fiber using artificial neural networks

Leonária Araújo Silva 
Lucas Benício Rodrigues Araújo 
Ana Karoliny Lemos Bezerra 
Arthur Hermont Fonseca Murta 
Lucas Feitosa de Albuquerque Lima Babadopulos 
Marcelo Silva Medeiros Júnior 

Resumo

Este artigo teve como foco a estimativa de propriedades mecânicas essenciais à concepção de estruturas de concreto mediante um modelo confiável de predição da resistência à compressão, à tração e à flexão de concreto reforçado com fibra de aço (CRFA) utilizando redes neurais artificiais (RNA), bem como avaliar a influência do teor de fibras nessas propriedades. A pesquisa utilizou um banco de dados com 57 estudos experimentais descritos na literatura, sendo implementado um modelo de rede neural com 12 variáveis de entrada, 1 de saída e 2 camadas ocultas com 16 neurônios. Como resultados, obtiveram-se as seguintes métricas indicadoras da qualidade do ajuste: um erro quadrático médio (MSE) de 22,63, 0,08 e 0,80, e um erro absoluto médio (MAE) de 3,64, 0,24 e 0,74 respectivamente para as resistências à compressão, à tração e à flexão. A análise da sensibilidade evidenciou que houve aumento considerável nas resistências à tração e à flexão com uso de fibras, o que é esperado. Os resultados confirmaram a capacidade de o modelo reproduzir de forma confiável as propriedades mecânicas do CRFA.

Palavras-chave: Concreto reforçado com fibra de aço (CRFA). Propriedades mecânicas. RNA. Análise de sensibilidade. Dosagem.

Abstract

The aim of this paper was to estimate the mechanical properties essential to the design of concrete structures through a reliable prediction model of the compressive, tensile and flexural strengths of concrete steel fiber reinforced concrete (CFRC) using Artificial Neural Networks (ANN), and also to evaluate the influence of the fiber content on these properties. The study used a database with 57 experimental studies from the literature, implementing a neural network model with 12 input variables, 1 output and 2 hidden layers with 16 neurons. The results obtained were a mean square error (MSE) of 22.63, 0.08 and 0.80, and a mean absolute error (MAE) of 3.64, 0.24 and 0.74, respectively, for the compressive, tensile and flexural strengths. The sensitivity analysis showed that there was a considerable increase in tensile and flexural strengths with the use of fibers, which was expected. The results confirmed the model's ability to reliably reproduce the mechanical properties of the CFRC.

Keywords: Steel fiber reinforced concrete. Mechanical properties. RNA. Sensitivity analysis. Dosage.

¹Leonária Araújo Silva
¹Universidade Federal do Ceará
Fortaleza - CE - Brasil

²Lucas Benício Rodrigues Araújo
²Universidade Federal do Ceará
Fortaleza - CE - Brasil

³Ana Karoliny Lemos Bezerra
³Universidade Federal do Ceará
Fortaleza - CE - Brasil

⁴Arthur Hermont Fonseca Murta
⁴Universidade Federal do Ceará
Fortaleza - CE - Brasil

⁵Lucas Feitosa de Albuquerque
Lima Babadopulos
⁵Universidade Federal do Ceará
Fortaleza - CE - Brasil

⁶Marcelo Silva Medeiros Júnior
⁶Universidade Federal do Ceará
Fortaleza - CE - Brasil

Recebido em 16/03/21
Aceito em 29/10/21

Introdução

O concreto é o material estrutural mais utilizado mundialmente, principalmente devido a seu baixo custo e a sua capacidade de ser moldado de diversas maneiras e formatos. É um material que exige mão de obra relativamente menos qualificada que outros materiais estruturais e tem boa resistência ao fogo, ao tempo e aos esforços mecânicos como choques e vibrações. Contudo, o concreto simples apresenta comportamento frágil na ruptura e tem baixa resistência à tração (SANJEEV; SAI NITESH, 2020). Classicamente, com o intuito de mitigar essas e outras limitações, o concreto é reforçado com barras de aço e, por essa razão, recebe a denominação de concreto armado (CA). Dessa forma, o aprimoramento de suas propriedades torna-se necessário para proporcionar um material mais eficiente (HODHOD; ABDEEN, 2011).

Outras tecnologias, que podem ser complementares, também permitem atacar essas desvantagens, uma delas sendo o uso de fibras desordenadas (diferentemente da armação de concreto armado) no reforço do concreto. O CA e o concreto reforçado com fibra de aço (CRFA) são compósitos formados por uma matriz e um material de reforço (FIGUEIREDO, 2011), com a diferença fundamental que, no concreto com fibras, isso é feito com elementos de tamanho da mesma ordem de grandeza das heterogeneidades já presentes no concreto, e com distribuição espacial aleatória.

No caso do concreto reforçado com fibra (CRF), o material de reforço pode ser fibras de vidro, polipropileno, carbono, nylon, polietileno, sisal, entre outras. Entretanto, quando o objetivo principal é a melhora das propriedades no estado endurecido, como tenacidade, capacidade de deformação após a ruptura, resistência à tração e à flexão, a fibra de aço costuma ser a mais indicada, pois é a que apresenta a melhor resistência à tração e o maior módulo de elasticidade (SIMÕES *et al.*, 2018).

As fibras de aço têm a capacidade de aumentar a ductilidade (IQBAL, 2019), a resistência ao cisalhamento (VITOR; SANTOS; TRAUTWEIN, 2018), a resistência à fadiga (TABASSUM *et al.*, 2018), a tenacidade (GUERINI *et al.*, 2018) e a resistência à tração (SANJEEV; SAI NITESH, 2020) do concreto, além de poder atuar na retenção de fissuras. Li *et al.* (2018a) conseguiram um ganho de tenacidade de 176,25% ao aumentar o teor de fibras de 0,5% para 1%.

As fibras de aço possuem também algumas desvantagens, por exemplo, o possível entrelaçamento e o intertravamento da mistura, o que afeta diretamente a trabalhabilidade do CRFA. Além disso, essas fibras podem apresentar alto custo, o que pode afetar significativamente o orçamento final da estrutura (QU; CAI; CHANG, 2018). Nesse contexto, é importante a realização da correção do traço-base para que as propriedades do concreto no estado fresco se mantenham e para que não ocorra aumento desnecessário do custo.

O desempenho dos concretos reforçados com fibras é influenciado tanto pelas diferentes dosagens, como pelas características das fibras:

- (a) resistência à tração;
- (b) comprimento;
- (c) diâmetro;
- (d) fator de forma;
- (e) teor; e
- (f) orientação (HAN *et al.*, 2019; WU *et al.*, 2016).

Por isso, diversas pesquisas vêm sendo desenvolvidas com a finalidade de entender quais os fatores que influenciam as principais propriedades dos CRFA.

Reddy e Rao (2020) fizeram a incorporação de fibras de aço e, quando comparado à amostra de controle, sem fibras, a resistência à compressão das amostras com adição de 0,5% e 2% de fibras aumentou em 20,38% e 25,56%, a resistência à tração teve incremento de 25,90% e 35,78%, e a resistência à flexão aumentou 31,86% e 41,14% respectivamente.

Predizer as principais propriedades do concreto afetadas pela adição de fibras de aço é essencial para potencializar a mistura de materiais, controlando o volume e as características das fibras de aço, além de reduzir os custos do concreto (QU; CAI; CHANG, 2018). Prever esse comportamento do concreto é um grande desafio tendo em vista as diferentes propriedades e a variedade dos materiais constituintes, principalmente o CRFA, que tem mais variáveis do que o CA. Por isso, os métodos estatísticos tradicionais

de modelagem não são capazes de relacionar os parâmetros de entrada (composicionais em sua maioria) e os de saída (relacionados à qualidade do material nos estados fresco e endurecido) de forma confiável.

Em decorrência das dificuldades mencionadas, a inteligência artificial surge como uma ferramenta que pode facilitar a redução do esforço na etapa de dosagem, economizando tempo e dinheiro, ao mesmo tempo em que se preserva a precisão dos resultados (HODHOD; ABDEEN, 2011). Entre as técnicas de Inteligência Artificial, existem as de aprendizado de máquina que podem fornecer uma solução para o problema de previsão de resistências do CRFA (KANG; YOO; GUPTA, 2021).

Ly *et al.* (2020) avaliaram dois algoritmos de aprendizado de máquina híbridos que combinaram rede neural artificial (RNA) com duas técnicas de otimização distintas, Real-Coded Algoritmo Genético (RCGA) e Algoritmo Firefly (FFA), para previsão de resistência ao cisalhamento de vigas de CRFA. Para isso, utilizaram um banco de dados com 463 resultados da literatura. Os autores concluíram que o algoritmo híbrido de RNA e RCGA foi melhor do que o RNA com FFA.

As RNA são uma das mais promissoras e vêm sendo utilizadas amplamente por diversos campos do conhecimento (LY *et al.*, 2020), inclusive no âmbito da engenharia civil. As RNA são sistemas inteligentes inspirados em sistemas neurais biológicos e são utilizadas para solucionar problemas complexos e não lineares devido a sua alta precisão e adaptabilidade (QU; CAI; CHANG, 2018). A principal vantagem dessa técnica se relaciona à capacidade de criação de um modelo automático de relacionamento entre as variáveis de entrada e saída usando dados com um algoritmo de aprendizado (HOSSAIN; GLADSON; ANWAR, 2017). Normalmente as etapas de ajuste de um modelo de RNA compreendem o treinamento (ajuste dos parâmetros de modelo, os neurônios, ao longo de épocas de análise, ou iterações), a validação (com ajustes de arquitetura, i.e. a disposição de camadas de neurônios, e verificação de deficiências como o *overfitting*) e o teste (em que se demonstra de maneira mais definitiva a capacidade preditiva da ferramenta sem novos ajustes, com obtenção final dos índices de acerto da RNA desenvolvida) (DEBIAZI; SOUZA, 2017).

Estudos apontam a capacidade das RNA em determinar a relação existente entre diferentes parâmetros com múltiplas variáveis de entrada e saída. Tavares *et al.* (2019) implementaram 10 modelos de RNA para estimativa da resistência à compressão do concreto utilizando 1.030 amostras de traços anteriores com resistências entre 2 MPa e 80 MPa. Essa quantidade de amostras foi alta devido ao maior número de pesquisas nessa área, diferentemente do CRFA. Em todos os modelos foram utilizados 70% dos dados para treinamento, 15% para validação e 15% para teste. Ao final, eles concluíram que o modelo com duas camadas de 15 e 16 neurônios obteve os melhores resultados, sendo o *Mean Square Error* – MSE (Erro Quadrático Médio) igual a 15,80 e 23 épocas respectivamente.

Hossain, Gladson e Anwar (2017) fizeram a previsão com RNA da resistência ao cisalhamento de vigas de concreto reforçadas com fibras de aço de diferentes formas. Eles utilizaram 239 dados experimentais, sendo 70% para treinamento e 30% para teste, e analisaram 9 modelos com diferentes camadas ocultas e 5 neurônios, alternando de 2 a 10 camadas. Com esses modelos, os erros variaram de 3,06 MPa a 6,95 MPa. Ao final, os autores concluíram que o modelo com 5 camadas ocultas foi o que teve melhor desempenho, pois obteve o menor MSE (3,06). Além disso, verificaram que o modelo de RNA é mais preciso do que as equações empíricas utilizadas usualmente para determinação da resistência ao cisalhamento de vigas de concretos reforçadas com fibras de aço.

No Brasil, alguns estudos também foram desenvolvidos utilizando RNA. Lorenzi *et al.* (2017) verificaram a possibilidade de se utilizar o ensaio de aderência aço/concreto para a estimativa da resistência do concreto por meio de RNA e concluíram que esse tipo de modelagem se apresentou como uma ferramenta eficaz para o tratamento dos dados propostos (562 amostras). Felix *et al.* (2018) fizeram uma análise numérica da vida útil de estruturas de concreto armado sujeitas a corrosão uniforme utilizando modelagem com RNA e com o Método dos Elementos Finitos e perceberam que o modelo foi eficiente.

As técnicas de inteligência artificial se apresentam como alternativas rápidas, simples, precisas, de baixo custo e com potencial de servir de suporte para a dosagem de CRFA. Contudo, a aplicabilidade dessas técnicas para previsão das principais propriedades mecânicas do CRFA é escassa e normalmente relaciona apenas uma dessas propriedades, além de não avaliarem o impacto da variação da quantidade de fibras nas resistências, o que é essencial para uma etapa eficiente de dosagem. Diante desse contexto, este artigo trata da estimativa de propriedades mecânicas essenciais à concepção de estruturas de concreto, buscando implementar três modelos confiáveis de previsão da resistência à compressão, à tração e à flexão de concretos reforçados com fibras de aço com base em RNA, e verificar a influência do teor de fibras nessas propriedades, por meio de uma análise de sensibilidade.

Método

O método, descrito nos próximos tópicos, contemplou as seguintes etapas: definição das ferramentas computacionais e das variáveis de entrada, construção do banco de dados, tratamento dos dados, modelagem preditiva com RNA e análise dos resultados finais.

Ferramentas computacionais utilizadas

Neste estudo foram utilizadas duas ferramentas computacionais: Microsoft Excel e a linguagem Python. Fez-se uso do Microsoft Excel versão 2010 para montar a base de dados para a modelagem (pré-processamento), bem como para o tratamento das variáveis e análise dos resultados após a saída dos valores da rede neural (pós-processamento). O Python versão 3.9 foi usado nas etapas de aprendizagem, validação e teste do modelo neural de predição das propriedades no estado endurecido do CRFA e na análise de sensibilidade. Essa linguagem foi escolhida por suportar os mais diversos tipos de algoritmos de treinamento de redes neurais, permitindo a execução de um grande número de simulações na tentativa de definir o modelo neural mais adequado. O ambiente computacional utilizado foi o sistema operacional Windows 10, CPU AMD2700X, memória RAM de 32GB e placa de vídeo GPU RTX2700.

Definição das variáveis de entrada

A definição das variáveis de entrada foi feita de acordo com diversos estudos que analisaram diferentes composições do CRFA e verificaram que os fatores que mais interferem no comportamento das propriedades do estado endurecido, como resistência à compressão, à tração e à flexão, estão relacionados tanto às características da fibra como as da matriz de concreto (FIGUEIREDO, 2011; HAN *et al.*, 2019; WU *et al.*, 2016; SANT'ANA, 2005).

As proporções adequadas dos constituintes da matriz de concreto são essenciais para proporcionar as propriedades nos estados fresco e endurecido requeridas para cada aplicação. Por exemplo, quanto maior a relação água-cimento, mais fluida é a pasta. Essa fluidez influencia diretamente a trabalhabilidade, ou seja, a capacidade de transporte, lançamento e adensamento do concreto. Porém, quanto mais alta a relação água-cimento, menor a resistência final do concreto, devido ao aumento da porosidade (HELENE; ANDRADE, 2007).

Assim, em relação às características da fibra, as variáveis de entrada avaliadas foram comprimento, fator de forma e teor. Para a matriz, foi considerada como dado de entrada a massa individual de cada material constituinte do traço (agregado graúdo, agregado miúdo, adições, cimento, água e aditivo).

Banco de dados

O banco de dados foi utilizado para treinamento, validação e teste do modelo das RNA, sendo composto de 1.051 registros, valor superior ao de outras pesquisas, como as expostas na introdução. Desse total, 521 apresentaram informações da resistência à compressão, 252 da resistência à tração e 278 da resistência à flexão, bem como seus respectivos dados de entrada, conforme disponibilidade dos dados na literatura. A Tabela 1 mostra a quantidade e a origem dos dados utilizados nesta pesquisa e encontra-se disponível no repositório Kaggle (KAGLE, 2021), sendo a organização do banco de dados em si uma contribuição do presente trabalho para pesquisas futuras.

O banco de dados foi construído mediante a busca por estudos anteriores no acervo dos periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) e em outros portais institucionais, por meio das seguintes palavras-chave: “*Steel Fiber*”, “*Concrete*”, “*Mechanical Properties*”, ou termos equivalentes. Após triagem manual, foram selecionadas 57 referências (Tabela 1) que continham dados relevantes para esta pesquisa, incluindo artigos de revistas e jornais e também dissertações e teses.

Pré-tratamento dos dados

O pré-tratamento de dados foi uma etapa fundamental, que precedeu o desenvolvimento do modelo neural. Tal tratamento precisou ser realizado para promover uma uniformização, de modo que todos os dados tivessem o mesmo formato e se encaixassem dentro de uma mesma categoria. Sendo assim, o banco de dados foi formado por resultados experimentais que atenderam aos seguintes requisitos:

- (a) não foram considerados agregados leves ou reciclados devido à pequena quantidade de estudos com esses materiais, bem como a esperada interferência nas variáveis de saída;
- (b) foi inserido apenas um tipo de fibra em cada amostra, sendo ela de aço, pois é a que apresenta a melhor resistência à tração e o maior módulo de elasticidade, além de contar com um maior número de estudos;
- (c) não foram considerados a ancoragem nas extremidades e o aspecto superficial (corrugada ou reta) que as fibras de aço podem assumir, a fim de evitar a grande variabilidade existente, sendo necessário incluir muitas variáveis de entrada;
- (d) outros tipos de concretos especiais, como concretos leves, pesados e autoadensáveis, não foram considerados;
- (e) foram utilizados concretos com diferentes resistências à compressão, à tração e à flexão, com valores mínimos e máximos mostrados na Tabela 2;
- (f) a variabilidade entre as dimensões dos corpos de prova de cada ensaio não foi considerada, sendo isso já levado em conta pela obtenção de propriedades intrínsecas dos materiais;
- (g) não foi feita diferenciação entre o ensaio de flexão de três pontos e o de quatro pontos;
- (h) todos os resultados de resistência à tração foram obtidos a partir do ensaio de tração na compressão diametral;
- (i) não foram considerados os diferentes tipos de cimentos e de aditivos presentes nas pesquisas, somente suas quantidades;
- (j) as adições foram divididas em quatro categorias, de acordo com o tipo:
 - cinza volante;
 - escória;
 - metacaulim; e
 - sílica ativa.
- (k) com exceção do fator de forma, que é adimensional, as unidades de medidas das variáveis foram padronizadas: comprimento da fibra em mm (milímetros), e as demais variáveis de entrada em kg/m³, enquanto as variáveis de saída foram padronizadas em MPa.

Modelagem preditiva

Redes neurais artificiais

O funcionamento das RNA é inspirado no sistema nervoso humano, sendo um algoritmo de aprendizado de máquina utilizado para prever qual será a saída dado um conjunto de entradas. Normalmente, são utilizadas RNA de múltiplas camadas, que possuem uma camada de entrada, pelo menos uma camada oculta e uma camada de saída. Essas camadas apresentam neurônios que se conectam, sem haver conexão entre neurônios de uma mesma camada. Os dados de entrada e os de saída são relacionados utilizando-se pesos que podem ser entendidos como o equivalente a coeficientes de correlação entre neurônios. Assim, o resultado será satisfatório se for obtido um conjunto de pesos estáveis, ou seja, se o programa conseguir aprender o problema (QU; CAI; CHANG, 2018).

A aprendizagem de uma RNA depende de um número elevado de dados de entrada e de saída, que servem para realizar o treinamento, que é subdividido em épocas para obter a relação entre os pesos que gera a melhor resposta. No decorrer do processo de treinamento, os pesos convergem gradualmente, reduzindo o erro entre os valores de saída estimados pela RNA e os valores experimentais que se quer ajustar. Neste estudo uma variação da busca de grade com momento (*Root Mean Square Propagation* – RMSprop) foi utilizada como estratégia para formalização dos parâmetros da rede neural.

Tabela 1 - Banco de dados obtido a partir da literatura e usado nesta pesquisa, indicando a numeração do trabalho, a quantidade de pontos experimentais de resistências à compressão (RC), à tração (RT) e à flexão (RF), e as referências

RC	RT	RF	Ref.	RC	RT	RF	Ref.		
3	3	-	Dhanapal e Jeyaprakash (2020)	4	-	-	Vasconcelos (2012)		
-	-	9	Nataraja, Dhang e Gupta (2000)	15	-	-	Jo, Shon e Kim (2001)		
4	4	4	Sanjeev e Sai Nitesh (2020)	-	4	4	Sharma <i>et al.</i> (2018)		
3	-	3	Chan, Liu e Galobardes (2020)	39	39	-	Yazici e Arel (2013)		
11	-	11	Venkateshwaran, Tan e Li (2018)	4	-	-	Setti <i>et al.</i> (2013)		
6	6	6	Reddy e Rao (2020)	20	20	20	Güneyisi <i>et al.</i> (2014)		
14	-	-	Marar, Eren e Roughani (2017)	5	-	5	Yoo e Moon (2018)		
7	7	7	Mohammadi, Singh e Kaushik (2008)	12	-	-	Lee, Oh e Cho (2015)		
30	30	10	Abbass, Khan e Mourad (2018)	13	13	-	Garcez (2005)		
3	-	-	Islam, Hussain e Morshed (2011)	7	-	7	Guimarães (2015)		
15	-	15	Atis e Karahan (2009)	4	4	4	Marcalíková <i>et al.</i> (2019)		
6	6	6	Altun, Haktanir e Ari (2007)	10	-	10	Guerini <i>et al.</i> (2018)		
10	10	10	Yazici, Inan e Tobak (2007)	11	-	-	Wu <i>et al.</i> (2020)		
12	-	11	Quanbing e Beirong (2005)	-	-	2	Kurihara <i>et al.</i> (2000)		
5	5	5	Afroughsabet e Ozbakkaloglu (2015)	15	15	12	Li <i>et al.</i> (2018a)		
4	-	-	Bencardino (2008)	10	10	10	Zheng <i>et al.</i> (2018)		
9	9	9	Samir, Faisal e Mohmd (2000)	35	-	-	Ou <i>et al.</i> (2012)		
7	6	4	Moscatelli (2011)	4	-	-	Pal <i>et al.</i> (2020)		
12	12	-	Thomas e Ramaswamy (2007)	-	-	9	Uygunoglu (2008)		
38	-	-	Marara, Erenb e Yitmena (2011)	4	4	-	Ba <i>et al.</i> (2016)		
6	6	6	Nili e Afroughsabet (2010)	4	4	4	Koksal <i>et al.</i> (2008)		
1	-	1	Periquito e Magalhães (2017)	10	10	10	Han <i>et al.</i> (2019)		
4	4	4	Ahmmad, Sallal e Mustafa (2019)	5	-	5	Luna <i>et al.</i> (2014)		
5	5	5	Ibrahim e Bakar (2011)	7	7	7	Iqbal <i>et al.</i> (2019)		
12	-	12	Karahan, Tanyildizi e Atis (2008)	9	-	9	Tabassum <i>et al.</i> (2018)		
3	-	3	Babaie, Abolfazli e Fahimifar (2019)	4	4	4	Rao e Rao (2009)		
10	-	10	Kumutha e Vijai (2009)	5	5	5	John e Brindha (2019)		
14	-	-	Nataraja, Dhang e Gupta (1999)	8	-	-	Li <i>et al.</i> (2018b)		
3	-	-	Monte, Toaldo e Figueiredo (2014)						
Total de Dados			RC			521	Total de Autores	RC	53
			RT			252		RT	27
			RF			278		RF	38

Tabela 2 - Valores mínimos e máximos das variáveis de entrada e de saída, associados às pesquisas com dados de resistências à compressão (RC), à tração (RT) e à flexão (RF)

Variável	RC		RT		RF	
	Min.	Máx.	Min.	Máx.	Min.	Máx.
Teor de fibras (kg/m)	0,0	312,4	0,0	235,0	0,0	312,4
Fator de forma (adm)	15,0	100,0	20,2	80,6	15,0	82,0
Comprimento da fibra (mm)	12,0	60,0	12,0	60,0	12,0	60,0
Consumo de agregado miúdo (kg/m)	446,6	1070,0	446,6	1070,0	446,6	1070,0
Consumo de agregado graúdo (kg/m)	399,5	1384,0	641,0	1384,0	641,0	1384,0
Consumo de água (kg/m)	72,0	272,4	137,0	240,0	88,0	230,8
Consumo de aditivo (kg/m)	0,0	36,3	0,0	36,3	0,0	36,3
Consumo de sílica ativa (kg/m)	0,0	127,6	0,0	120,8	0,0	120,8
Consumo de escória (kg/m)	0,0	200,0	0,0	97,2	0,0	97,4
Consumo de cinza volante (kg/m)	0,0	172,0	0,0	0,0	0,0	120,0
Consumo de metacaulim (kg/m)	0,0	44,6	0,0	44,6	0,0	44,6
Consumo de cimento (kg/m)	160,0	598,9	194,8	598,9	194,8	598,9
Resistência (MPa)	13,0	121,0	1,6	9,9	1,4	16,5

Utilizou-se o aprendizado supervisionado por ser adequado para problemas em que já se conhece previamente os resultados esperados para determinado conjunto de dados, sendo o método normalmente empregado para as RNA, e a função de ativação Relu (ABUODEH; ABDALLA; HAWILEH, 2020). O aprendizado supervisionado busca ajustar os parâmetros da rede para encontrar a relação mais apropriada entre os pesos. À medida que são inseridos os dados de entrada, há comparação entre a resposta esperada e a calculada pela rede, sendo feito um ajuste dos pesos das conexões a fim de reduzir o erro. É importante observar como a evolução do erro ocorre, a fim de identificar sua estabilização ou outro comportamento. Então, é necessário construir o gráfico relacionando o erro com uma quantidade alta de épocas para visualizar a faixa de épocas que proporcionam uma convergência da rede (estabilização), sem apresentar *overfitting*. O *overfitting* ocorre quando a RNA memoriza os padrões de treinamento sem extrair as características gerais para ser eficiente na generalização dos padrões (IMAM; ANIFOWOSE; AZAD, 2015). Em seguida, dentro da faixa de épocas encontradas, são analisados vários modelos, para encontrar o número de épocas que forneça menor esforço computacional e baixo erro.

Os dados de validação são avaliados durante a etapa de treinamento, a cada época, obtendo-se como resultado um erro. Esse processo se repete até que sejam atingidas as épocas preestabelecidas. Ao final do procedimento, são utilizados os pesos que possibilitam o menor erro de validação como resultado do treinamento. Em seguida, a RNA usa esses valores nos dados de teste, sendo um indicativo do desempenho real da RNA, já que esses dados não foram utilizados no treinamento e são bons indicadores para o desempenho da RNA (CHEN *et al.*, 2020).

Implementação do modelo com RNA

O desenvolvimento do modelo neural se deu com o treinamento, validação e teste de diversas topologias até o encontro do modelo que melhor se ajustou ao conjunto de dados. Foram utilizadas a biblioteca Pandas versão 1.2.0 do Python para tratamento do banco de dados, Numpy versão 1.19.2 para operações matriciais, e Matplotlib para a visualização dos dados. Além dessas, foi utilizado o ambiente para aprendizado de máquina TensorFlow versão 2.3.2.

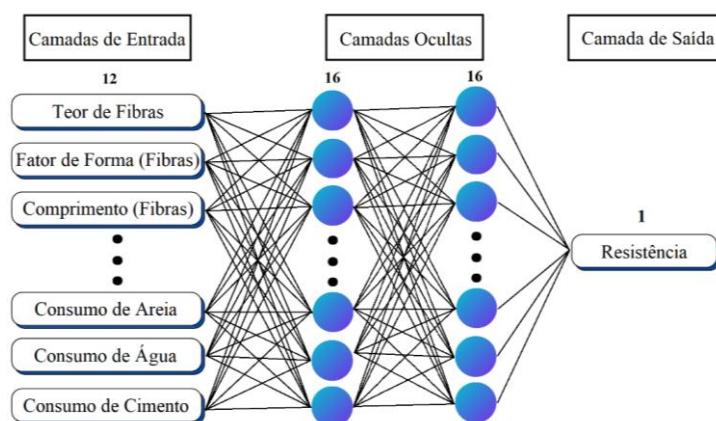
Do total de resultados pertencentes ao banco de dados, foram separados aleatoriamente 90% para treinamento e validação e 10% para teste do modelo. Dos 90% iniciais, 80% foram utilizados para o treinamento e 20% para a validação. Sublinha-se que são valores próximos aos empregados na literatura (ABAMBRES; LANTSOGHT, 2019). Inicialmente, os dados passaram por um pré-processamento para sua normalização, por meio da subtração do valor médio da variável e posterior divisão do resultado pelo desvio padrão.

Os parâmetros envolvidos em um algoritmo de RNA permitem grande variação nas possibilidades de treinamento, o que torna inviável a simulação de todas as configurações possíveis. Para esta pesquisa, foram testados modelos com diferentes quantidades de camadas ocultas, neurônios e iterações para definição do modelo a se adotar. Esse procedimento foi necessário para que fosse definida a configuração mais adequada para o conjunto de dados desta pesquisa, ou seja, a configuração que apresentou menor MSE e menor *Mean Absolute Error* (MAE, erro absoluto médio). Definida a configuração adequada da rede, foram feitas 30 execuções independentes e realizada a análise estatística dos resultados obtidos.

Assim, após várias simulações, concluiu-se que o modelo com 2 camadas com 16 neurônios cada foi o que produziu os melhores resultados. Por fim, a arquitetura adotada neste estudo foi de 12 variáveis de entrada, 2 camadas com 16 neurônios e 1 variável de saída para cada modelo. Os valores abrangidos pelos ajustes efetuados nesta pesquisa são mostrados na Figura 1.

Para analisar a capacidade preditiva da rede neural, o código forneceu o MSE e o MAE. O MSE é a média das diferenças quadráticas entre os valores reais e os estimados e apresenta como vantagem independência em relação à quantidade de dados analisados. Já o MAE é a média das diferenças entre os valores reais e os estimados. Quanto menores forem o MSE e o MAE, melhor o modelo se comporta, ou seja, para MSE e MAE iguais a zero não existe erro no modelo, mas, ao se compararem os resultados, deve-se considerar a ordem de grandeza dos parâmetros originais.

Figura 1 - Configuração da RNA



Análise de sensibilidade

Estudos (JIAO *et al.*, 2019; PIANOSI; WAGENER, 2015) vêm sendo realizados a fim de avaliar a influência dos parâmetros de entrada do modelo na saída. Essa análise de sensibilidade possibilita identificar a coerência do modelo com a experiência prévia e determinar se a relação encontrada é adequada (TZUC *et al.*, 2021). Nesta pesquisa, uma análise de sensibilidade foi realizada pelo método de Morris a fim de verificar a influência do teor de fibras nas propriedades mecânicas dos CRFA.

Inicialmente, o modelo utilizou valores médios das variáveis de entrada para obter uma resistência-base. Em seguida, foram simulados novos resultados com acréscimo do teor de fibras (5%, 10%, 20%, 30%, 40%, 50%, 60% e 70%), mantendo-se fixos os valores médios das outras variáveis de entrada. Assim, foram obtidas novas resistências, que foram comparadas com a resistência no cenário-base.

Resultados e discussões

Após a modelagem preditiva da resistência à compressão, à tração e à flexão, os resultados obtidos a partir do modelo neural foram analisados através dos valores de MSE e de MAE. Em seguida, verificaram-se os resultados da análise de sensibilidade.

Resistência à compressão

A Tabela 3 mostra os valores reais e os estimados a partir da etapa de teste da execução individual que apresentou o menor MSE e a diferença entre eles. Ademais, na 3ª e na 6ª coluna, calculou-se o quanto esse valor variou em relação ao real, percentualmente. Também foram apresentados o valor de MAE e o de MSE, que foram de 3,64 e de 22,63 respectivamente. Verificou-se que a diferença entre os valores reais e os previstos variou em torno de 7,24%.

Inicialmente, o MAE pode ser considerado alto, mas, tendo em vista a ordem de grandeza dos valores da resistência à compressão, esse valor é aceitável. Alguns resultados estimados apresentaram diferença considerável em relação aos dados reais, o que resultou no alto MSE encontrado, uma vez que as diferenças estão elevadas ao quadrado.

A Figura 2a mostra como as curvas de erro de treinamento e de validação se comportam ao longo das épocas. Percebe-se que as curvas se estabilizam, ou seja, se tornam horizontais e sem *overfitting* com aproximadamente 7.000 épocas.

Tabela 3 - Resultados da resistência à compressão

Real (MPa)	Previsto (MPa)	Variação (%)	Real (MPa)	Previsto (MPa)	Variação (%)
49,48	36,87	-25,5	42,77	42,54	-0,5
56,00	45,21	-19,3	42,30	42,08	-0,5
49,80	41,91	-15,8	82,80	82,44	-0,4
50,30	43,91	-12,7	52,20	52,13	-0,1
53,00	46,57	-12,1	42,40	42,36	-0,1
73,50	67,19	-8,6	77,00	77,11	0,1
65,90	60,26	-8,6	43,90	44,53	1,4
88,97	81,96	-7,9	67,40	68,49	1,6
59,70	55,18	-7,6	43,74	44,62	2,0
36,12	33,69	-6,7	40,90	42,10	2,9
62,30	58,24	-6,5	53,05	54,88	3,5
52,40	49,00	-6,5	31,90	33,06	3,6
73,80	69,23	-6,2	75,40	79,12	4,9
46,81	43,92	-6,2	34,60	36,42	5,3
30,20	28,39	-6,0	77,00	82,13	6,7
43,80	41,63	-4,9	61,70	65,90	6,8
92,70	88,62	-4,4	54,22	58,49	7,9
64,10	61,40	-4,2	65,00	70,44	8,4
89,52	86,22	-3,7	110,90	120,28	8,5
34,70	33,79	-2,6	27,21	29,71	9,2
90,30	88,52	-2,0	34,11	37,44	9,8
64,20	63,31	-1,4	41,10	46,73	13,7
63,30	62,53	-1,2	48,90	56,32	15,2
32,83	32,63	-0,6	38,50	45,68	18,6
83,50	83,02	-0,6	25,05	32,19	28,5
81,00	80,55	-0,6	28,30	37,88	33,8
MAE		3,64	MSE		22,63

Observa-se na Figura 2b que os pontos estão entre -25% e +35% da linha de igualdade e que foram analisadas diferentes faixas de resistências. Assim, do ponto de vista quantitativo, o banco de dados da resistência à compressão tem boa representatividade. No entanto, para que ocorra maior aproximação dos pontos à linha de igualdade, é necessário considerar alguns parâmetros relacionados ao CRFA e aos ensaios experimentais durante a modelagem, que não foram abordados nesta pesquisa porque não constavam em todos os artigos, tais como o aspecto superficial da fibra, a falta de correção dos traços com a incorporação de fibras e a dimensão dos corpos de prova. Logo, diante dos resultados expostos, percebe-se que o modelo proposto tem potencial para ser utilizado para prever o comportamento de resistência à compressão de CRFA, dentro da faixa de 13 MPa a 121 MPa.

Resistência à tração

O modelo de RNA possibilitou prever a resistência à tração do CRFA. A Tabela 4 apresenta os valores reais e estimados pela RNA da execução individual que apresentou o menor MSE, mostrando que o MAE foi de 0,24 e que o MSE foi de 0,08, sendo inferiores ao da resistência à compressão. Essas diferenças se justificam devido a suas diferentes ordens de grandeza e à menor variação entre os resultados estimados em relação aos dados reais. Verificou-se também que a diferença entre os valores reais e previstos variou em torno de 6,43%.

A Figura 3a mostra que as curvas de erro de treinamento e de validação ficaram estáveis e sem a presença de *overfitting* com 4.000 épocas. A Figura 3b mostra que os valores estimados se aproximaram dos resultados experimentais, tendo variação, em relação à linha de igualdade, de -10% a +25%. Além disso, pode-se notar que foram avaliados diferentes valores de resistência e que alguns pontos se afastaram da aglomeração central, mas continuaram próximos à linha de igualdade, o que indica que o modelo se adequa a valores de resistência à tração que variam de 1,6 MPa a 9,9 MPa.

Figura 2 - Resultados da resistência à compressão (RC)

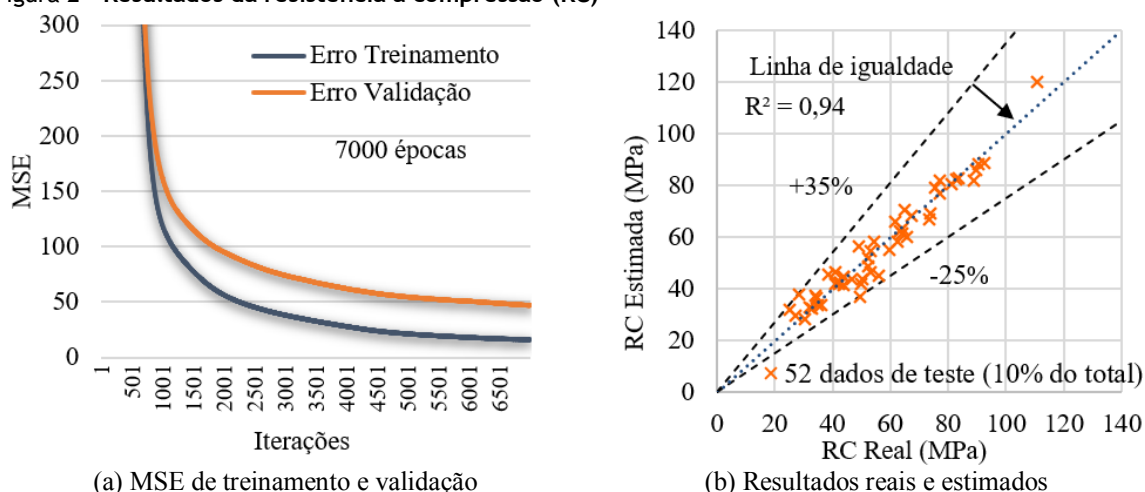
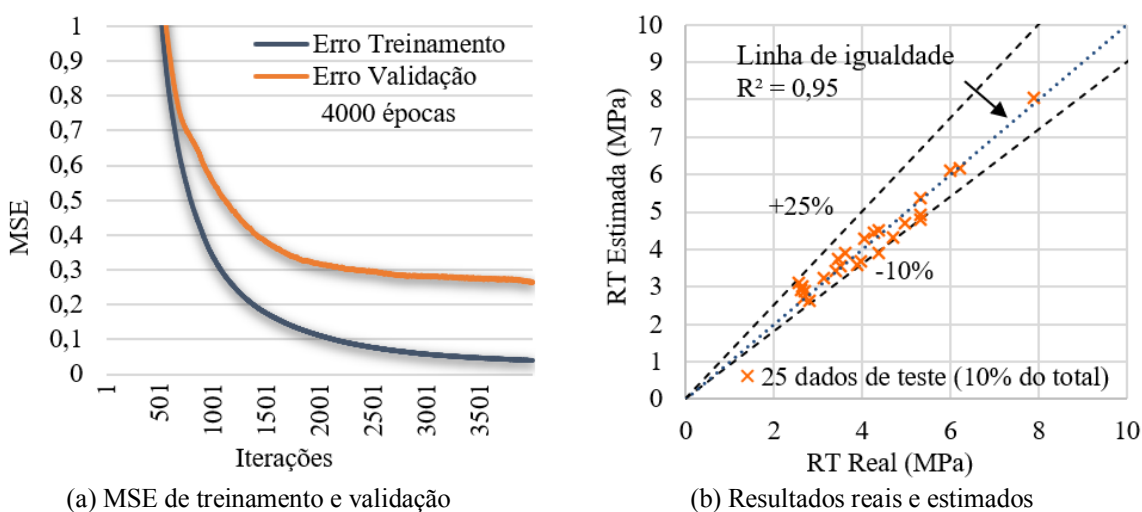


Tabela 4 - Resultados da resistência à tração

Real (MPa)	Previsto (MPa)	Variação (%)	Real (MPa)	Previsto (MPa)	Variação (%)
4,37	3,90	-10,8	6,00	6,11	1,8
5,32	4,80	-9,7	7,90	8,06	2,0
4,71	4,32	-8,3	4,37	4,51	3,2
3,89	3,57	-8,2	3,12	3,25	4,1
5,33	4,91	-7,9	4,27	4,45	4,2
3,96	3,67	-7,2	4,06	4,28	5,3
2,79	2,62	-6,1	2,70	2,89	7,0
4,98	4,69	-5,8	3,62	3,89	7,5
6,21	6,17	-0,7	3,45	3,74	8,5
3,40	3,42	0,7	2,62	2,90	10,8
2,67	2,70	1,1	2,63	3,02	14,8
5,31	5,37	1,2	2,55	3,12	22,4
3,52	3,57	1,3			
MAE		0,24	MSE		0,08

Figura 3 - Resultados da resistência à tração (RT)



Resistência à flexão

Com o intuito de analisar a capacidade preditiva do modelo proposto para a resistência à flexão, foi construída a Tabela 5 e os gráficos da Figura 4. A Tabela 5 mostra os valores reais e os previstos no teste da execução individual que apresentou o menor MSE, sendo o MAE de 0,74 e o MSE de 0,80, superiores aos da resistência à tração. Isso indica que o modelo proposto melhor se adequou à resistência à tração do que à flexão, já que ambos apresentam a mesma ordem de grandeza e praticamente a mesma quantidade de dados. Verificou-se também que a diferença entre os valores reais e previstos variou em 12,74%.

A Figura 4a apresenta as curvas do erro de treinamento e de validação, na qual é possível perceber que foram necessárias cerca de 6.000 épocas para a estabilização desses erros. Na Figura 4b percebe-se que os pontos estão entre -30% e +35%, o que indica que o modelo se adéqua a valores de resistência à flexão que variam de 1,4 MPa a 13,1 MPa.

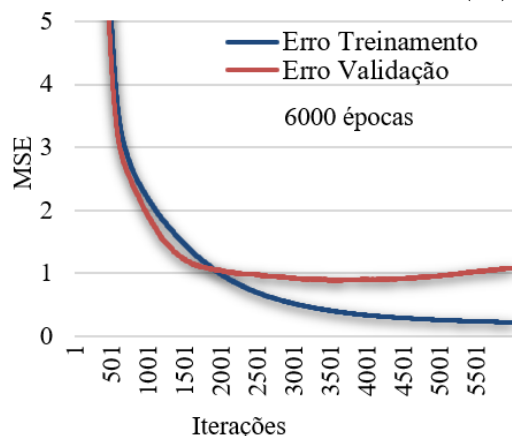
Análise estatística dos resultados

Foram construídos gráficos *boxplots* com os valores de MSE de 30 execuções independentes, mostrados na Figura 5, para visualizar a distribuição e *outliers* dos dados a fim de fornecer uma perspectiva sobre a capacidade preditiva do modelo neural. No *boxplot* os limites superior e inferior representam o valor máximo e mínimo da amostra respectivamente, o marcador “x” indica o valor da média, e as linhas horizontais do retângulo demonstram os valores do primeiro quartil, mediana e terceiro quartil, conforme ilustrado na Figura 5c.

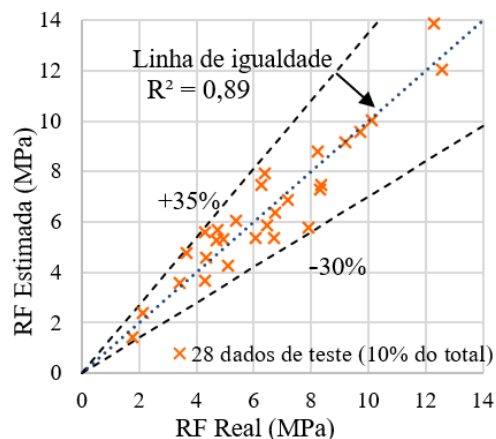
Tabela 5 - Resultados de resistência à flexão

Real (MPa)	Previsto (MPa)	Variação (%)	Real (MPa)	Previsto (MPa)	Variação (%)
7,90	5,75	-27,2	9,21	9,17	-0,4
6,70	5,37	-19,9	3,40	3,58	5,4
1,78	1,44	-19,1	4,35	4,59	5,5
5,10	4,27	-16,3	8,24	8,79	6,7
4,31	3,68	-14,6	4,96	5,31	7,0
8,30	7,26	-12,5	2,14	2,36	10,4
6,08	5,36	-11,8	4,70	5,29	12,5
8,35	7,47	-10,5	12,30	13,85	12,6
6,48	5,84	-9,9	5,38	6,06	12,7
6,76	6,34	-6,2	6,25	7,47	19,5
12,58	12,02	-4,4	4,73	5,68	20,1
7,20	6,88	-4,4	6,37	7,92	24,4
9,72	9,58	-1,5	4,31	5,57	29,3
10,13	10,01	-1,1	3,64	4,77	31,1
MAE		0,74	MSE		0,80

Figura 4 - Resultados da resistência à flexão (RF)



(a) MSE de treinamento e validação



(b) Resultados reais e estimados

Os dados da compressão e da tração foram assimétricos, pois a maioria dos valores está localizada na parte superior do gráfico. Já os dados da flexão foram simétricos, indicando que o conjunto é normalmente distribuído. Observou-se que não ocorreram *outliers*, mostrando que não teve nenhum resultado muito distante dos dados centrais. Em relação à dispersão dos dados, a tração apresentou a maior diferença entre o terceiro quartil e o primeiro quartil (tamanho da caixa), indicando que teve maior variabilidade quando comparado com os demais, sendo a flexão o melhor resultado desse parâmetro. Percebeu-se ainda que os valores médios do MSE foram de 41,13, 0,25 e 1,21 para a resistência à compressão, à tração e à flexão respectivamente.

Análise de sensibilidade

Foi conduzida uma análise de sensibilidade, variando-se a quantidade de fibras, em quilograma por metro cúbico, e verificando-se o efeito nas variáveis de saída (resistências). A Tabela 6 mostra os traços originais para cada resistência. O teor de fibras original para a resistência à compressão, à tração e à flexão foi de 66,8 kg/m³, 54,6 kg/m³ e 55,2 kg/m³ respectivamente. A Figura 6 mostra os resultados da análise de sensibilidade, com padrões aproximadamente lineares para o aumento das resistências com o acréscimo percentual do teor de fibras em relação ao traço original presente na Tabela 6. Percebeu-se que, à medida que se aumentou o teor de fibras, houve um pequeno ganho médio de resistência à compressão, de aproximadamente 0,05% para cada 1% de aumento no teor de fibra em relação ao original. Além disso, verifica-se que a elevação desse teor gerou um crescimento significativo da resistência à tração, tendo uma taxa de cerca de 0,18% para cada 1% de aumento no teor de fibra em relação ao original. Esse aumento foi ainda mais notório ao se analisar a resistência à flexão, que apresentou taxa de crescimento de aproximadamente 0,65% para cada 1% de teor de fibras adicional.

Esses resultados estão em conformidade com a literatura, uma vez que Sanjeev e Sai Nitesh (2020) encontraram que a resistência à compressão aumentou 12%, a resistência à tração 25% e a resistência à flexão 40% quando o teor de fibras aumentou 70%. Marar, Eren e Roughani (2017) relataram que, em relação à amostra sem fibra, o aumento da resistência à compressão das amostras com fibra variou de 4% a 24% e que, na resistência à flexão, o acréscimo variou entre 40% e 70%.

Por fim, os resultados enfatizaram a atuação das fibras de aço, que, de acordo com a literatura, agem como pequenas pontes de tensão através de fissuras, auxiliando na melhor distribuição das tensões de tração e de flexão, não tendo influência significativa na resistência à compressão (REDDY; RAO, 2020; ZHENG *et al.*, 2018).

Figura 5 - *Boxplot* do MSE

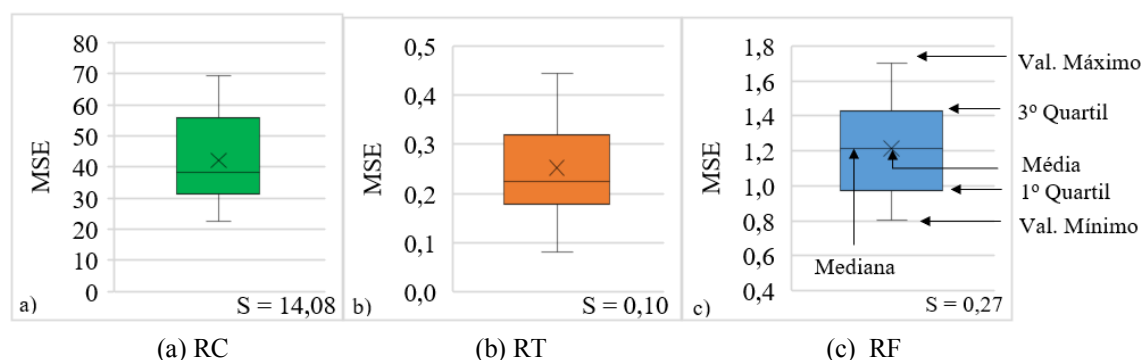
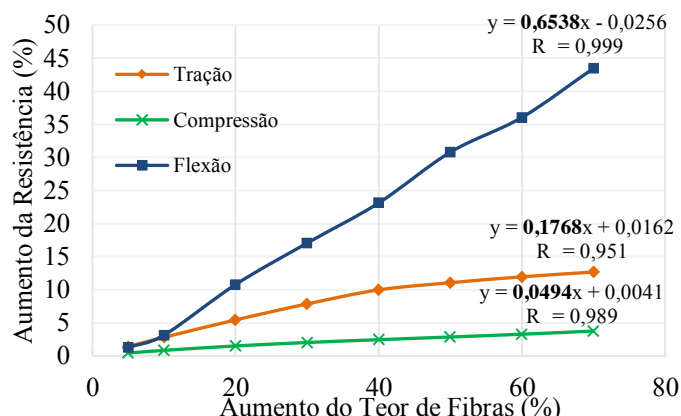


Tabela 6 - Traços originais

Resistência	Cimento	Agregado miúdo	Agregado graúdo	Água	Teor de aditivo	Sílica ativa	Escória	Cinza volante	Metacaulim	Teor de fibra
Compressão	1	1,822	2,384	0,430	0,012	0,021	0,034	0,019	0,002	0,159
Tração	1	1,886	2,447	0,419	0,012	0,019	0,005	0,000	0,004	0,131
Flexão	1	1,948	2,578	0,438	0,011	0,010	0,004	0,015	0,004	0,139

Figura 6 - Análise de sensibilidade



Conclusão

Com o objetivo de fornecer uma ferramenta para auxiliar o processo de dosagem do CRFA, nesta pesquisa uma modelagem utilizando RNA foi realizada a fim de estimar as resistências à compressão, à tração e à flexão de concretos reforçados com fibras de aço e de analisar a influência do teor de fibras nessas propriedades por meio de uma análise de sensibilidade. Para avaliar a precisão desse método, foi utilizado o MSE e o MAE. Dessa forma, a partir dos resultados obtidos, pode-se concluir o que se segue:

- os resultados das simulações confirmaram a capacidade de o modelo reproduzir de forma confiável, simples e com baixo custo as propriedades de resistência à compressão, à tração e à flexão do CRFA, já que o MSE foi de 31,29, 0,08 e 0,80; o MAE, de 3,85, 0,24 e 0,74; e a diferença entre os valores reais e previstos variou, em média, entre 7,24%, 6,43% e 12,74% respectivamente;
- a análise da sensibilidade evidenciou a relação entre o acréscimo do teor de fibras e o ganho de resistência, mostrando que houve aumento considerável nas resistências à tração e à flexão, sendo menos significativo na resistência à compressão;
- quando comparamos nossa base de dados (1.051) com a de outros autores, citados na introdução, percebe-se que a quantidade de dados utilizados neste artigo foi superior, sendo adequada para a predição realizada. Sublinha-se que a literatura não reporta um número exato, mas indica que, quanto mais dados, melhor será a qualidade da previsão. Com o aumento do banco de dados e a consideração de outros parâmetros, como dimensão e formato dos corpos de prova, e aspecto superficial das fibras, os resultados encontrados têm grande possibilidade de serem melhorados. Contudo, o aumento do banco de dados é dependente da quantidade de artigos existentes e do desenvolvimento de novas pesquisas;
- ressalta-se que a inserção de fibras de aço nos CRFA interfere em outras propriedades, além das mecânicas; por exemplo, a trabalhabilidade. Assim, durante a dosagem, deve-se considerar ainda a interferência do teor de fibras no estado fresco do CRFA; e
- recomenda-se para pesquisas futuras o desenvolvimento de um aplicativo computacional destinado à geração de estimativas diretas dos valores de resistência à compressão, à tração e à flexão de concretos reforçados com fibra de aço como meio para acelerar a dosagem dos concretos com fibras.

Referências

- ABAMBRES, M.; LANTSOGH, E. O. L. ANN-Based shear capacity of steel fiber-reinforced concrete beams without stirrups. **Fibers**, v. 7, n. 10, 2019.
- ABBASS, W.; KHAN, M. I.; MOURAD, S. Evaluation of mechanical properties of steel fiber reinforced concrete with different strengths of concrete. **Construction and Building Materials**, v. 168, p. 556-569, 2018.
- ABUODEH, O. R.; ABDALLA, J. A.; HAWILEH, R. A. Assessment of compressive strength of ultra-high performance concrete using deep machine learning techniques. **Applied Soft Computing Journal**, v. 95, n. 40, 2020.

- AFROUGHSABET, V.; OZBAKKALOGLU, T. Mechanical and durability properties of high-strength concrete containing steel and polypropylene fibers. **Construction and Building Materials**, v. 94, p. 73-82, 2015.
- AHMAD, A.; SALLAL, A.; MUSTAFA, O. Experimental investigation on the effect of steel fibers on the flexural behavior and ductility of high-strength concrete hollow beams. **Advances in Civil Engineering**, v. 2019, jan. 2019.
- ALTUN, F.; HAKTANIR, T.; ARI, K. Effects of steel fiber addition on mechanical properties of concrete and RC beams. **Construction and Building Materials**, v. 21, n. 3, p. 654-661, 2007.
- ATIŞ, C. D.; KARAHAN, O. Properties of steel fiber reinforced fly ash concrete. **Construction and Building Materials**, v. 23, n. 1, p. 392-399, 2009.
- BA, H. *et al.* Experimental study on the M20 grade cement concrete containing crimped steel fibres. **International Journal of Science Technology & Engineering**, v. 3, set. 2016.
- BABAIE, R.; ABOLFAZLI, M.; FAHIMIFAR, A. Mechanical properties of steel and polymer fiber reinforced concrete. **Journal of the Mechanical Behavior of Materials**, v. 28, p. 119-134, 2019.
- BENCARDINO, F. Stress-strain behavior of steel fiber-reinforced concrete in compression. **Journal of Materials in Civil Engineering**, v. 20, n. 3, p. 255-263, 2008.
- CHAN, R.; LIU, X.; GALOVARDES, I. Parametric study of functionally graded concretes incorporating steel fibres and recycled aggregates. **Construction and Building Materials**, v. 242, p. 118-186, 2020.
- CHEN, S. *et al.* Sensitivity analysis to reduce duplicated features in ANN training for district heat demand prediction. **Energy and AI**, v. 2, n. 15, p. 100028, 2020.
- DEBIAZI, P. R.; SOUZA, L. C. L. Contribuição de parâmetros do entorno urbano sobre o ambiente térmico de um campus universitário. **Ambiente Construído**, Porto Alegre, v. 17, n. 4, p. 215-232, out./dez. 2017.
- DHANAPAL, J.; JEYAPRAKASH, S. Mechanical properties of mixed steel fiber reinforced concrete with the combination of micro and macro steel fibers. **Structural Concrete**, v. 21, n. 1, p. 458-467, 2020.
- FELIX, E. F. *et al.* Análise da vida útil de estruturas de concreto armado sob corrosão uniforme por meio de um modelo com RNA acoplado ao MEF. **Revista ALCONPAT**, v. 8, n. 1, p. 1-15, 2018.
- FIGUEIREDO, A. D. **Concreto reforçado com fibras**. São Paulo, 2011. 256 f. Tese (Doutorado em Engenharia Civil) – Escola de Engenharia, Universidade de São Paulo, São Paulo, 2011.
- GARCEZ, E. O. **Análise teórico-experimental do comportamento de concretos reforçados com fibras de aço submetidos a cargas de impacto**. Porto Alegre, 2005. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.
- GUERINI, V. *et al.* Influence of steel and macro-synthetic fibers on concrete properties. **Fibers**, v. 6, n. 3, 2018.
- GUIMARÃES, D. **Avaliação das propriedades de concretos reforçados com fibras de aço para utilização em pisos industriais**. Porto Alegre, 2015. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.
- GÜNEYISI, E. *et al.* Combined effect of steel fiber and metakaolin incorporation on mechanical properties of concrete. **Composites Part B: Engineering**, v. 56, p. 83-91, 2014.
- HAN, J. *et al.* Effects of steel fiber length and coarse aggregate maximum size on mechanical properties of steel fiber reinforced concrete. **Construction and Building Materials**, v. 209, p. 577-591, 2019.
- HELENE, P.; ANDRADE, T. Concreto de cimento Portland. In: ISAIA, G. C. **Materiais de construção civil e princípios de ciência e engenharia de materiais**. São Paulo: IBRACON, 2007.
- HODHOD, H.; ABDEEN, A. M. Simulation and prediction for the effect of natural and steel fibers on the performance of concrete using experimental analyses and artificial neural networks numerical modeling. **KSCE Journal of Civil Engineering**, v. 15, n. 8, p. 1373-1380, 2011.
- HOSSAIN, K. M. A.; GLADSON, L. R.; ANWAR, M. S. Modeling shear strength of medium to ultra-high-strength steel fiber-reinforced concrete beams using artificial neural network. **Neural Computing and Applications**, v. 28, n. 1, p. 1119-1130, 2017.

- IBRAHIM, I. S.; BAKAR, M. B. C. Effects on mechanical properties of industrialised steel fibres addition to normal weight concrete. **Procedia Engineering**, v. 14, p. 2616-2626, 2011.
- IMAM, A.; ANIFOWOSE, F.; AZAD, A. K. Residual strength of corroded reinforced concrete beams using an adaptive model based on ANN. **International Journal of Concrete Structures and Materials**, v. 9, n. 2, p. 159-172, 2015.
- IQBAL, S. *et al.* Enhanced mechanical properties of fiber reinforced concrete using closed steel fibers. **Materials and Structures**, v. 52, n. 3, 2019.
- ISLAM, S. M.; HUSSAIN, R. R.; MORSHED, M. A. Z. Fiber-reinforced concrete incorporating locally available natural fibers in normal- and high-strength concrete and a performance analysis with steel fiber-reinforced composite concrete. **Journal of Composite Materials**, v. 46, n. 1, p. 111-122, 2011.
- JIAO, P. *et al.* High-performance fiber reinforced concrete as a repairing material to normal concrete structures: experiments, numerical simulations and a machine learning-based prediction model. **Construction and Building Materials**, v. 223, p. 1167-1181, 2019.
- JO, B. W.; SHON, Y. H.; KIM, Y. J. The evaluation of elastic modulus for steel fiber reinforced concrete. **Russian Journal of Nondestructive Testin**, v. 37, n. 2, p. 152-161, 2001.
- JOHN, V. J.; BRINDHA, D. Effect of steel macro fibers on engineering properties of copperslag-concrete. **Structural Concrete**, v. 21, n. 2, p. 689-702, 2019.
- KAGLE. **Steel fiber reinforced concrete ANN**. Disponível em: <https://www.kaggle.com/arthurmurta/steel-fiber-reinforced-concreteann>. Acesso em: 24 maio 2021.
- KANG, M. C.; YOO, D. Y.; GUPTA, R. Machine learning-based prediction for compressive and flexural strengths of steel fiber-reinforced concrete. **Construction and Building Materials**, v. 266, p. 121117, 2021.
- KARAHAN, O.; TANYILDIZI, H.; ATIS, C. D. An artificial neural network approach for prediction of long-term strength properties of steel fiber reinforced concrete containing fly ash. **Journal of Zhejiang University-SCIENCE A**, v. 9, n. 11, p. 1514-1523, 2008.
- KOKSAL, F. *et al.* Combined effect of silica fume and steel fiber on the mechanical properties of high strength concretes. **Construction and Building Materials**, v. 22, p. 1874-1880, 2008.
- KUMUTHA, R.; VIJAI, K. Effect of steel fibers on the properties of concrete. **Journal of Reinforced Plastics and Composites**, v. 29, n. 4, p. 531-538, 2009.
- KURIHARA, N. *et al.* Tension softening diagrams and evaluation of properties of steel fiber reinforced concrete. **Engineering Fracture Mechanics**, v. 65, n. 2, p. 235-245, 2000.
- LEE, S. C.; OH, J. H.; CHO, J. Y. Compressive behavior of fiber-reinforced concrete with end-hooked steel fibers. **Materials**, v. 8, n. 4, p. 1442-1458, 2015.
- LI, B. *et al.* Effects of fiber type, volume fraction and aspect ratio on the flexural and acoustic emission behaviors of steel fiber reinforced concrete. **Construction and Building Materials**, v. 181, p. 474-486, 2018a.
- LI, F. *et al.* Experimental study of the basic mechanical properties of directionally distributed steel fibre-reinforced concrete. **Advances in Materials Science and Engineering**, v. 2018, jun. 2018b.
- LORENZI, A. *et al.* Aplicação de redes neurais artificiais na predição da aderência aço-concreto em ensaios do tipo pull-out. **Revista IBRACON de Estruturas e Materiais**, v. 10, n. 5, p. 1051-1074, 2017.
- LUNA, A. *et al.* Experimental mechanical characterization of steel and polypropylene fiber reinforced concrete. **Revista Técnica de la Facultad de Ingeniería Universidad del Zulia**, v. 37, n. 2, p. 106-115, 2014.
- LY, H. B. *et al.* Computational hybrid machine learning based prediction of shear capacity for steel fiber reinforced concrete beams. **Sustainability**, v. 12, n. 7, article 2709, 2020.
- MARAR, K.; EREN, Ö.; ROUGHANI, H. The influence of amount and aspect ratio of fibers on shear behaviour of steel fiber reinforced concrete. **KSCE Journal of Civil Engineering**, v. 21, n. 4, p. 1393-1399, 2017.

- MARARA, K.; ERENB, Ö.; YITMENA, İ. Compression specific toughness of normal strength steel fiber reinforced concrete (NSSFRC) and high strength steel fiber reinforced concrete (HSSFRC). **Materials Research**, v. 14, n. 2, p. 239-247, 2011.
- MARCALÍKOVÁ, Z. *et al.* Comparison of material properties of steel fiber reinforced concrete with two types of steel fiber. **IOP Conference Series: Materials Science and Engineering**, v. 549, n. 1, p. 012-039, 2019.
- MOHAMMADI, Y.; SINGH, S. P.; KAUSHIK, S. K. Properties of steel fibrous concrete containing mixed fibres in fresh and hardened state. **Construction and Building Materials**, v. 22, n. 5, p. 956-965, 2008.
- MONTE, R.; TOALDO, G. S.; FIGUEIREDO, A. D. Avaliação da tenacidade de concretos reforçados com fibras através de ensaios com sistema aberto. **Revista Matéria**, v. 19, n. 2, p. 132-149, 2014.
- MOSCATELLI, I. **Fibras de aço em concreto de cimento Portland aplicados a pavimento**. Campinas, 2011. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade Estadual de Campinas, Campinas, 2011.
- NATARAJA, M. C.; DHANG, N.; GUPTA, A. P. Stress-strain curves for steel-fiber reinforced concrete under compression. **Cement & Concrete Composites**, v. 21, p. 383-390, 1999.
- NATARAJA, M. C.; DHANG, N.; GUPTA, A. P. Toughness characterization of steel fiber-reinforced concrete by JSCE Approach. **Cement and Concrete Research**, v. 30, n. 4, p. 593-597, 2000.
- NILI, M.; AFROUGHSABET, V. Combined effect of silica fume and steel fibers on the impact resistance and mechanical properties of concrete. **International Journal of Impact Engineering**, v. 37, n. 8, p. 879-886, 2010.
- OU, Y. C. *et al.* Compressive behavior of steel-fiber-reinforced concrete with a high reinforcing index. **Journal of Materials in Civil Engineering**, v. 24, n. 2, p. 207-215, 2012.
- PAL, S. *et al.* Strength characteristics and microstructure of hooked-end steel fiber reinforced concrete containing fly ash, bottom ash and their combination. **Construction and Building Materials**, v. 247, n. 41, 2020.
- PERIQUITO, M. S.; MAGALHÃES, M. S. Mechanical behaviour of steel fiber reinforced concrete with stone powder. **Revista Matéria**, v. 22, n. 2, fev. 2017.
- PIANOSI, F.; WAGENER, T. A Simple and efficient method for global sensitivity analysis based on cumulative distribution functions. **Environmental Modelling & Software**, v. 67, p. 1-11, 2015.
- QU, D.; CAI, X.; CHANG, W. Evaluating the effects of steel fibers on mechanical properties of ultra-high performance concrete using artificial neural networks. **Applied Sciences-Basel**, v. 8, n. 7, p. 1120, 2018.
- QUANBING, Y.; BEIRONG, Z. Effect of steel fiber on the deicer-scaling resistance of concrete. **Cement and Concrete Research**, v. 35, n. 12, p. 2360-2363, 2005.
- RAO, G.; RAO, A. S. Toughness indices of steel fiber reinforced concrete under mode II loading. **Materials and Structures**, v. 42, n. 9, p. 1173-1184, 2009.
- REDDY, S. V. B.; RAO, P. S. Experimental studies on mechanical properties and impact characteristics of ternary concrete with steel fiber. **Materials Today: Proceedings**, v. 27, n. 21, p. 788-797, 2020.
- SAMIR, A.; FAISAL, W.; MOHMD, K. Effect of the concrete compressive strength and tensile reinforcement ratio on the flexural behavior of fibrous concrete beams. **Engineering Structures**, v. 22, p. 1145-1158, 2000.
- SANJEEV, J.; SAI NITESH, K. J. N. Study on the effect of steel and glass fibers on fresh and hardened properties of vibrated concrete and self-compacting concrete. **Materials Today: Proceedings**, v. 27, p. 1559-1568, 2020.
- SANT'ANA, M. V. **Modelo numérico para concretos reforçados com fibras**. Rio de Janeiro, 2005. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade Estadual do Norte Fluminense, Rio de Janeiro, 2005.
- SETTI, B. *et al.* Compressive, flexural and abrasive performances of steel fiber reinforced concrete elements. **International Journal of Mechanical Engineering and Applications**, v. 1, n. 3, p. 69-77, 2013.

- SHARMA, S. *et al.* Durability study of high-strength steel fiber-reinforced concrete. **Materials Journal**, v. 115, n. 2, p. 219-225, 2018.
- SIMÕES, T. *et al.* Influence of type and dosage of micro-fibres on the physical properties of fibre reinforced mortar matrixes. **Construction and Building Materials**, v. 187, p. 1277-1285, 2018.
- TABASSUM, N. *et al.* A Study on the compressive & flexural strength behavior of steel fiber reinforced concrete beam. **International Journal of Advanced Research**, v. 6, n. 8, p. 557-567, 2018.
- TAVARES, D. S. *et al.* Uso de redes neurais artificiais na predição da resistência à compressão do concreto. In: CONGRESSO DA PÓS-GRADUAÇÃO DA UFLA, 28., Lavras, 2019. **Anais [...]** Lavras, 2019.
- THOMAS, J.; RAMASWAMY, A. Mechanical properties of steel fiber-reinforced concrete. **Journal of Materials in Civil Engineering**, v. 19, n. 5, p. 385-392, 2007.
- TZUC, O. M. *et al.* Modeling of hygrothermal behavior for green facade's concrete wall exposed to nordic climate using artificial intelligence and global sensitivity analysis. **Journal of Building Engineering**, v. 33, n. 96, 2021.
- UYGUNOGLU, T. Investigation of microstructure and flexural behavior of steel-fiber reinforced concrete. **Materials and Structures**, v. 41, p. 1441-1449, 2008.
- VASCONCELOS, R. E. **Fratura do concreto reforçado com fibras de aço e de polipropileno e meios normal e agressivo**. Campinas, 2012. Tese (Doutorado em Engenharia Civil) – Escola de Engenharia, Universidade Estadual de Campinas, Campinas, 2012.
- VENKATESHWARAN, A.; TAN, K. H.; LI, Y. Residual flexural strengths of steel fiber reinforced concrete with multiple hooked-end fibers. **Structural Concrete**, v. 19, p. 352-365, 2018.
- VITOR, P. C. P.; SANTOS, A. C.; TRAUTWEIN, L. M. Resistência ao cisalhamento em vigas de concreto armado sem armadura transversal reforçadas com fibras de aço. **Ambiente Construído**, Porto Alegre, v. 18, n. 3, p. 255-270, jul./set. 2018.
- WU, F. *et al.* Compressive and flexural properties of ultra-high performance fiber-reinforced cementitious composite: the effect of coarse aggregate. **Composite Structures**, v. 236, p. 111810, 2020.
- WU, Z. *et al.* Effects of steel fiber content and shape on mechanical properties of ultra high performance concrete. **Construction Building Materials**, v. 103, p. 8-14, 2016.
- YAZICI, S.; AREL, H. S. The effect of steel fiber on the bond between concrete and deformed steel bar in SFRCs. **Construction and Building Materials**, v. 40, p. 299-305, 2013.
- YAZICI, S.; İNAN, G.; TOBAK, V. Effect of aspect ratio and volume fraction of steel fiber on the mechanical properties of SFRC. **Construction and Building Materials**, v. 21, p. 1250-1253, 2007.
- YOO, D. Y.; MOON, D. Y. Effect of steel fibers on the flexural behavior of RC beams with very low reinforcement ratios. **Construction and Building Materials**, v. 188, p. 237-254, 2018.
- ZHENG, Y. *et al.* Mechanical properties of steel fiber-reinforced concrete by vibratory mixing technology. **Advances in Civil Engineering**, v. 2018, p. 1-11, dec. 2018.

Leonária Araújo Silva

Departamento de Engenharia Estrutural e Construção Civil | Universidade Federal do Ceará | Campus do Pici, s/n, Bloco 733 | Fortaleza - CE - Brasil | CEP 60440-900 | Tel.: (88) 99675-7558 | E-mail: leonaria@alu.ufc.br

Lucas Benício Rodrigues Araújo

Departamento de Engenharia Estrutural e Construção Civil | Universidade Federal do Ceará | Tel.: (88) 99667-4831 | E-mail: lucasbenicio@alu.ufc.br

Ana Karoliny Lemos Bezerra

Departamento de Engenharia de Transportes | Universidade Federal do Ceará | Tel.: (88) 99603-8362 | E-mail: anakarolinylemos@alu.ufc.br

Arthur Hermont Fonseca Murta

Departamento de Estatística e Matemática Aplicada | Universidade Federal do Ceará | Campus do Pici, s/n, Bloco 910 | Fortaleza - CE - Brasil | CEP 60440-900 | Tel.: (85) 99955-9052 | E-mail: art_murta@hotmail.com

Lucas Feitosa de Albuquerque Lima Babadopulos

Departamento de Engenharia Estrutural e Construção Civil | Universidade Federal do Ceará | Tel.: (85) 3366-9607 | E-mail: babadopulos@ufc.br

Marcelo Silva Medeiros Júnior

Departamento de Engenharia Estrutural e Construção Civil | Universidade Federal do Ceará | Tel.: (85) 3366-9607 | E-mail: marcelomedeiros@ufc.br

Ambiente Construído

Revista da Associação Nacional de Tecnologia do Ambiente Construído

Av. Osvaldo Aranha, 99 - 3º andar, Centro

Porto Alegre - RS - Brasil

CEP 90035-190

Telefone: +55 (51) 3308-4084

www.seer.ufrgs.br/ambienteconstruido

www.scielo.br/ac

E-mail: ambienteconstruido@ufrgs.br



This is an open-access article distributed under the terms of the Creative Commons Attribution License.