



III MCSM

# Modelagem Computacional no Sertão Mineiro



PPGMCS  
Programa de Pós-Graduação em  
Modelagem Computacional e Sistemas

## PREVISÃO DE CARGA DE RUPTURA DE VIGAS DE CONCRETO ARMADO COM REDES NEURAIS MLP

**Maria Luiza Almeida Xavier**<sup>1</sup> - maria.luiza.a.xavier@gmail.com

**Jordana Gabriela Fernandes**<sup>1</sup> - jordana.funai@gmail.com

**Rayre Janaína Vieira Silva**<sup>1</sup> - rayrejanaina2@gmail.com

<sup>1</sup>Universidade Estadual de Montes Claros, UNIMONTES - Montes Claros, MG, Brazil

**Abstract.** *O comportamento mecânico de vigas de concreto armado envolve fenômenos complexos e não lineares que representam desafios ao dimensionamento estrutural convencional. Nesse contexto, este trabalho propõe a aplicação de uma rede neural artificial do tipo Multi-Layer Perceptron (MLP), implementada em Python, para a estimativa da carga de ruptura de vigas de concreto armado a partir de parâmetros geométricos e mecânicos. Os dados de treinamento foram gerados sinteticamente por meio de uma equação matemática simplificada contendo um termo de interação não linear e ruído gaussiano, simulando variações experimentais típicas de ensaios laboratoriais. A normalização por z-score e o otimizador Adam foram empregados no treinamento, conduzido ao longo de 3000 épocas. O modelo alcançou  $R^2 = 0,8957$  e  $RMSE = 5,05$  kN no conjunto de teste, demonstrando que a arquitetura MLP com ativação tanh é capaz de capturar adequadamente as relações não lineares entre as variáveis estruturais. Os resultados reforçam o potencial das redes neurais como ferramentas complementares aos métodos tradicionais da engenharia estrutural, sinalizando perspectivas promissoras para aplicações com bases de dados experimentais mais amplas.*

**Keywords:** *Redes neurais artificiais, Concreto armado, Carga de ruptura, Multi-Layer Perceptron, Aprendizado de máquina.*

## 1. INTRODUÇÃO

Os fenômenos estruturais ligados ao concreto armado são desafios importantes da engenharia civil, principalmente porque envolve muitos fatores complexos. Características como o comportamento não linear do concreto, o surgimento de fissuras, a interação entre o aço e o concreto e as variações nas propriedades dos materiais podem afetar diretamente a resistência e a segurança das construções.

Por isso, entender como funciona a resistência estrutural é necessário para o correto dimensionamento de vigas de concreto armado. Normalmente, a engenharia utiliza fórmulas tradicionais baseadas em experimentos, normas técnicas e conceitos da resistência dos materiais. Porém, esses métodos podem apresentar limitações diante da complexidade real do comportamento estrutural.

Nesse contexto, técnicas de inteligência artificial têm sido cada vez mais utilizadas na engenharia estrutural, especialmente para prever o comportamento mecânico das estruturas. Entre essas técnicas, destacam-se as Redes Neurais Artificiais, principalmente o modelo Multi-Layer Perceptron (MLP), que possui grande capacidade de identificar relações complexas e não lineares entre diferentes variáveis. Segundo Goodfellow, Bengio e Courville (2016), modelos neurais profundos possuem elevada capacidade de aproximação universal, permitindo identificar padrões complexos em bases de dados experimentais.

O trabalho propõe uma rede neural MLP para prever a carga de ruptura de vigas de concreto armado a partir de parâmetros geométricos e mecânicos. A hipótese é que o modelo consiga estimativas próximas aos cálculos convencionais, avaliadas por métricas estatísticas. A justificativa é modernizar e agilizar a análise estrutural integrando Deep Learning ao dimensionamento de estruturas.

## 2. REFERENCIAL TEÓRICO

Na engenharia civil, a determinação da carga de ruptura de vigas de concreto armado é tradicionalmente realizada por meio das formulações da mecânica das estruturas e da resistência dos materiais. Esses métodos permitem avaliar a capacidade resistente dos elementos estruturais a partir do comportamento conjunto entre concreto e aço, considerando os esforços internos gerados pelas cargas aplicadas à estrutura. Segundo Botelho (2015), o dimensionamento de vigas de concreto armado fundamenta-se no equilíbrio entre as forças de compressão atuantes no concreto e as forças de tração absorvidas pela armadura de aço.

O concreto armado caracteriza-se pela atuação complementar entre dois materiais com propriedades mecânicas distintas. O concreto apresenta elevada resistência à compressão, porém baixa resistência à tração, enquanto o aço possui elevada capacidade resistente aos esforços de tração. De acordo com Araújo (2014), essa associação possibilita que o concreto armado apresente comportamento estrutural adequado diante dos esforços de flexão presentes em vigas.

A análise estrutural de vigas considera parâmetros geométricos e mecânicos fundamentais, como resistência característica do concreto, taxa de armadura, altura útil da seção transversal e propriedades mecânicas do aço. A partir dessas variáveis, é possível calcular o momento resistente da estrutura, isto é, sua capacidade máxima de suportar esforços sem atingir o estado limite último de ruptura. Conforme estabelece a ABNT NBR 6118 (2023), o dimensionamento à flexão de vigas deve garantir segurança estrutural, estabilidade e desempenho adequado da estrutura.

A representação matemática simplificada do momento resistente último em vigas submetidas à flexão simples pode ser expressa pela seguinte equação:

$$M_u = A_s f_y \left( d - \frac{a}{2} \right) \quad (1)$$

Nessa formulação,  $(M_u)$  representa o momento resistente último da seção estrutural;  $(A_s)$  corresponde à área da armadura de aço;  $(f_y)$  refere-se à tensão de escoamento do aço;  $(d)$

representa a altura útil da viga; e  $(a)$  corresponde à profundidade do bloco comprimido de concreto.

A área da armadura de aço ( $A_s$ ) está relacionada à quantidade de aço inserida na estrutura para resistir aos esforços de tração. Segundo Carvalho e Figueiredo Filho (2014), o aumento da taxa de armadura tende a elevar a capacidade resistente da viga, desde que sejam respeitados os limites normativos de ductilidade e segurança estrutural.

A tensão de escoamento do aço ( $f_y$ ) representa o limite a partir do qual o material passa a sofrer deformações permanentes. Esse parâmetro é fundamental no dimensionamento estrutural, pois define a capacidade resistente da armadura submetida aos esforços de tração. Conforme Bastos (2023), as propriedades mecânicas do aço influenciam diretamente o comportamento resistente e a ductilidade das estruturas de concreto armado.

O termo  $(d - (a/2))$  representa o braço de alavanca interno da seção estrutural, isto é, a distância efetiva entre as resultantes internas de compressão no concreto e tração no aço. A altura útil da viga ( $d$ ) corresponde à distância entre a região comprimida do concreto e o centro geométrico da armadura tracionada, enquanto  $(a/2)$  representa metade da profundidade do bloco comprimido equivalente. Segundo Leonhardt (1977), o aumento do braço de alavanca interno contribui significativamente para o crescimento da capacidade resistente ao momento fletor.

A formulação clássica de flexão simples com armadura simples é a base do dimensionamento estrutural convencional, mas a complexidade do comportamento do concreto armado tem motivado o uso de inteligência artificial como complemento aos métodos analíticos. Nesse contexto, as Redes Neurais Artificiais se destacam por modelar relações não lineares entre variáveis estruturais. Segundo Goodfellow, Bengio e Courville (2016), modelos neurais profundos possuem elevada capacidade de aproximação universal, permitindo identificar padrões complexos em bases de dados experimentais. Entre essas arquiteturas, o MLP apresenta grande potencial para prever resistência e comportamento mecânico de elementos estruturais.

### 3. METODOLOGIA

A metodologia baseia-se na aplicação de uma rede neural artificial do tipo Multi-Layer Perceptron (MLP) para estimativa da carga de ruptura de vigas de concreto armado. O modelo foi implementado em Python utilizando as bibliotecas NumPy, Scikit-learn e Matplotlib.

Em substituição à formulação clássica da engenharia estrutural, foi adotada uma equação matemática simplificada para geração dos dados sintéticos de treinamento:

$$P = 0,35 \cdot f_c + 12 \cdot \rho + 2,1 \cdot d - 0,02 \cdot f_c \cdot d + \varepsilon \quad (2)$$

em que  $f_c$  é a resistência característica do concreto (MPa),  $\rho$  a taxa de armadura (%),  $d$  a altura útil da seção (cm),  $P$  a carga de ruptura estimada (kN) e  $\varepsilon \sim \mathcal{N}(0, 1,5)$  um ruído gaussiano que simula variações experimentais. O termo de interação  $-0,02 f_c \cdot d$  foi introduzido para incorporar efeitos não lineares entre as variáveis, tornando o problema mais próximo do comportamento estrutural real.

As variáveis foram definidas nos intervalos  $f_c \in [25, 50]$  MPa,  $\rho \in [0,5\%, 2,5\%]$  e  $d \in [30, 60]$  cm. Foi gerada uma base de dados composta por 1000 amostras sintéticas, utilizando os intervalos  $f_c \in [25, 50]$  MPa,  $\rho \in [0, 5\%, 2, 5\%]$  e  $d \in [30, 60]$  cm. As variáveis de entrada da rede neural correspondem a  $f_c$ ,  $\rho$  e  $d$ , enquanto a saída é a carga de ruptura  $P$ .

A base foi dividida aleatoriamente em 30% para treinamento e 70% para teste, proporção adotada propositalmente para submeter o modelo a um conjunto de teste mais amplo e, assim, avaliar de forma mais rigorosa sua capacidade de generalização. Antes do treinamento, todas as variáveis foram normalizadas pelo método *z-score*:

$$x_{norm} = \frac{x - \mu}{\sigma} \quad (3)$$

em que  $\mu$  e  $\sigma$  representam a média e o desvio padrão calculados a partir do conjunto de treinamento.

A arquitetura da MLP foi composta por uma camada de entrada com três neurônios, duas camadas ocultas com 16 e 8 neurônios e uma camada de saída com um neurônio, conforme ilustrado na Figura 1. As camadas ocultas utilizaram a função de ativação *tanh*, enquanto a camada de saída empregou ativação linear.




Figure 1: Arquitetura da rede neural MLP utilizada para previsão da carga de ruptura.

O treinamento foi realizado durante 3000 épocas, utilizando o algoritmo Adam, taxa de aprendizado de  $10^{-3}$  e tamanho de lote de 32 amostras.

#### 4. RESULTADOS E DISCUSSÃO

As Figuras 2 e 3 apresentam a comparação entre os valores reais e os valores previstos pela rede MLP para os conjuntos de treinamento e teste, respectivamente.




Figure 2: Comparação entre os valores reais e previstos para o conjunto de treinamento.

Observa-se na Figura 2 elevada concordância entre os valores previstos e os valores reais, indicando que a rede neural foi capaz de aprender adequadamente a relação entre as variáveis de entrada e a carga de ruptura. Pequenas discrepâncias são observadas em alguns pontos isolados, mas sem comprometer o desempenho global do modelo.




Figure 3: Comparação entre os valores reais e previstos para o conjunto de teste.

A Figura 3 demonstra que a rede manteve boa capacidade de generalização ao ser aplicada a amostras não utilizadas durante o treinamento. Mesmo diante da variabilidade introduzida na base de dados, as previsões acompanham satisfatoriamente a tendência dos valores reais, evidenciando a capacidade da MLP de representar relações não lineares entre as variáveis do problema.

A Tabela 1 apresenta as métricas de desempenho obtidas para os conjuntos de treinamento e teste.

Table 1: Métricas de desempenho da rede MLP.

| Métrica      | Treino | Teste  |
|--------------|--------|--------|
| MAE (kN)     | 1,3772 | 1,8178 |
| RMSE (kN)    | 2,6660 | 5,0496 |
| $R^2$        | 0,9695 | 0,8957 |
| MAPE (%)     | 1,4698 | 1,8421 |
| Acurácia (%) | 98,67  | 96,14  |

Os resultados indicam elevado desempenho preditivo da rede neural. Os baixos valores de MAE e MAPE demonstram que os erros médios de previsão permaneceram reduzidos, enquanto os coeficientes de determinação obtidos ( $R^2 = 0,9695$  para treinamento e  $R^2 = 0,8957$  para teste) evidenciam forte correlação entre os valores previstos e observados. Além disso, a acurácia superior a 96% para o conjunto de teste confirma a capacidade de generalização do modelo, indicando que a arquitetura proposta é adequada para a estimativa da carga de ruptura de vigas de concreto a partir dos parâmetros considerados.

## 5. CONCLUSÃO

Neste trabalho foi desenvolvida uma rede neural artificial do tipo Multi-Layer Perceptron para estimar a carga de ruptura de vigas de concreto a partir da resistência do concreto, taxa de armadura e altura útil da seção.

Os resultados demonstraram elevado desempenho preditivo, com coeficientes de determinação superiores a 0,89, erro percentual médio inferior a 2% e acurácia superior a 96% no conjunto de teste. Além disso, a proximidade entre os erros obtidos nos conjuntos de treinamento e teste indica boa capacidade de generalização da rede.

Dessa forma, conclui-se que a arquitetura proposta foi capaz de modelar com sucesso a relação não linear entre as variáveis analisadas, mostrando o potencial das redes neurais

artificiais como ferramenta para estimativas de parâmetros estruturais. Como trabalhos futuros, sugere-se a utilização de dados experimentais reais e a comparação do desempenho da MLP com outras técnicas de inteligência artificial aplicadas à engenharia estrutural.

### ***Agradecimentos***

Os autores agradecem à FAPEMIG (grant n OET-00243-26).

### **REFERENCES**

- [1] ARAÚJO, José Milton de. **Curso de concreto armado**. 4. ed. Rio Grande: Dunas, 2014. Disponível em: <https://www.editoradunas.com.br/dunas/V4.pdf>. Acesso em: 13 maio 2026.
- [2] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6118: Projeto de estruturas de concreto — Procedimento**. Rio de Janeiro: ABNT, 2023.
- [3] BASTOS, Paulo Sérgio dos Santos. **Fundamentos do concreto armado**. Bauru: UNESP, 2023. Disponível em: <https://wwwp.feb.unesp.br/pbastos/concreto1/Fundamentos%20CA.pdf>. Acesso em: 13 maio 2026.
- [4] BOTELHO, Manoel Henrique Campos; MARCHETTI, Osvaldemar. **Concreto armado eu te amo**. 8. ed. São Paulo: Blucher, 2015. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 13 maio 2026.
- [5] CARVALHO, Roberto Chust; FIGUEIREDO FILHO, Jasson Rodrigues de. **Cálculo e detalhamento de estruturas usuais de concreto armado: segundo a NBR 6118:2014**. 4. ed. São Paulo: EdUFSCar, 2014. 415 p. ISBN 9788576003564.
- [6] GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016. Disponível em: <https://www.deeplearningbook.org/>. Acesso em: 13 maio 2026.
- [7] LEONHARDT, Fritz; MONNIG, Eduard. **Construções de concreto: princípios básicos do dimensionamento de estruturas de concreto armado**. 1. ed. Rio de Janeiro: Interciência, 1977. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 13 maio 2026.