



A: XXXIX-0000

## UMA ABORDAGEM COMPUTACIONAL PARA PREVER A FORÇA DE ARRANCAMENTO DE BARRAS FINAS DE AÇO EM CONCRETO USANDO ÁRVORES DE DECISÃO ALEATÓRIAS E FLORESTA RANDÔMICA

### A COMPUTATIONAL APPROACH TO PREDICT THE PULL-OUT FORCE OF THIN STEEL BARS IN CONCRETE USING RANDOM DECISION TREES AND RANDOM FOREST

Priscila F. Silva (A) (1), Gray F. Moita (2), Eliene P. Carvalho (2), Vanderci F. Arruda (1)

(1) Eng. Civil, Estudante DSc, Centro Federal de Educação Tecnológica, Belo Horizonte, Brasil.

(2) Dr. Prof., Centro Federal de Educação Tecnológica, Belo Horizonte, Brasil.

Endereço para correspondência: pritiesilva@gmail.com; (A) Apresentador

**Área temática:** Análise Estrutural: Métodos Computacionais

#### Resumo

A força de ligação entre barras de aço e o concreto é um dos aspectos essenciais para o funcionamento das estruturas de concreto armado. Como essa ligação é um fator influenciado por diversas variáveis, descrever seu comportamento pode ser desafiador. Diversos são os estudos científicos sobre essa propriedade, contudo, esses estudos geralmente se referem a barras com diâmetros superiores a 12 mm. Poucos estudos avaliaram o desempenho de barras com diâmetros menores que 10 mm, incluindo diâmetros de 5,0, 6,3, 8,0 e 9,5 mm. Recentemente, avanços tecnológicos no aprendizado de máquinas conseguiram propor diversas soluções para os variados problemas de engenharia. Nesse sentido, este estudo tem como objetivo prever a tensão de arrancamento de barras finas em ensaios pull-out empregando métodos de aprendizado de máquinas, como árvores de decisão aleatória (DTR) e florestas randômicas (RFR). O banco de dados utilizado nesse trabalho é composto de 89 amostras experimentais de arrancamento. Os dados utilizados na modelagem continham quatro parâmetros de entrada: conformação superficial e diâmetro ( $\phi$ ) das barras, resistência à compressão do concreto ( $f_c$ ) e comprimento de ancoragem da barra de aço ( $L_d$ ). O estudo comparou o desempenho dos algoritmos a partir da raiz do erro quadrático médio (RMSE) e do  $R^2$  encontrados. Com isso, o RMSE obtido foi de 1,30 e 1,26 kN e o  $R^2$  foi de 0,95 e 0,96 para os modelos DTR e RFR, respectivamente. Por fim, o estudo pôde concluir que os modelos de máquinas de aprendizado propostos podem prever de forma razoável a tensão de arrancamento de barras finas no concreto através de ensaios pull-out e tendem a apresentar melhores resultados com um aumento no número de amostras na base de dados. Assim, os métodos de aprendizagem computacional apresentados poderão ser utilizados para o desenvolvimento de modelos preditivos para a tensão de arrancamento.

*Palavras-chave:* Árvores de decisão, Barras Finas de Aço, Floresta Aleatória, Ligação aço-concreto.

#### Abstract

The bond strength between steel bars and concrete is one of the essential aspects of reinforced concrete structures and is generally affected by several variables. Hence, describing its behavior



can be challenging. There are several scientific studies about this property, however, these studies usually refer to bars with diameters greater than 12 mm. Few studies have evaluated the performance of bars with diameters smaller than 10 mm, including the diameters of 5.0, 6.3, 8.0, and 9.5 mm. Recently, technological advances in machine learning have managed to propose several solutions to the different engineering problems. In this regard, this study aims to predict the pulling stress of thin bars in pull-out tests by employing machine learning methods such as random decision trees (DFR) and random forests (RFR). The database used in the current work consists of 89 experimental pull-out samples. The data used in the modeling contained four input parameters: bar surface, bar diameter ( $\phi$ ), concrete compressive strength ( $f_c$ ) and the anchorage length ( $L_d$ ). The study compared the performance of the algorithms using the root mean square error (RMSE) and the  $R^2$  found. With that, the RMSE obtained were 1.26 and 1.30 kN and the  $R^2$  were 0.95 and 0.96 for the DTR and RFR models, respectively. Finally, the study could conclude that the proposed machine learning models can reasonably predict the pull-out stress of thin bars in concrete through pull-out tests and tend to show better results with an increase in the number of samples in the database. Thus, the computational learning methods presented could be used for the development of predictive models for pull-out tension.

*Keywords: Steel-concrete bond; Thin rebars; decision trees; Random forests.*

## 1. INTRODUÇÃO

A aderência do concreto e das barras de aço é uma propriedade que garante o bom desempenho das estruturas de concreto armado, pois assegura que aço e concreto trabalhem juntos, formando uma peça solidária. O conhecimento desse comportamento é fundamental para avaliar a capacidade de carga das estruturas de concreto armado, sendo inclusive condição básica para o controle da fissuração das estruturas e das definições das regras de projeto, para o cálculo de ancoragem das barras de aço e das emendas traspassadas em elementos de concreto armado (Barbosa, 2001).

O grande número de parâmetros envolvidos no estudo do comportamento da ligação é um desafio no entendimento da aderência do aço com o concreto nas estruturas de concreto armado. Uma melhor compreensão de como tais parâmetros influenciam na determinação do comportamento dessas estruturas, onde é essencial a correta determinação das distribuições de tensões e deslocamentos nessas ligações. Em geral, o rompimento da ligação pode ocorrer por dois processos, arrancamento da barra ou fendilhamento da peça de concreto. Em uma falha de arrancamento, ocorre o esmagamento do concreto entre nervuras e a barra é puxada para fora do corpo de prova. Já no fendilhamento, ocorre ruptura devido ao desenvolvimento de rachaduras ao longo do eixo longitudinal do corpo de prova. A falha de arrancamento, em geral, ocorre quando o confinamento da barra é satisfatório. Quando esse confinamento não é, então a ruptura por fendilhamento acontece (Miranda *et al.*, 2021).

Com isso, pode-se dizer que para a determinação da tensão de aderência são utilizadas variáveis como o diâmetro da barra, tipo da barra, disposição das nervuras e a resistência característica das barras de aço, suas posições em relação à direção de concretagem e o comprimento de ancoragem. Essa quantidade de variáveis associadas ao fenômeno de aderência aço-concreto pode influenciar de diversas maneiras a determinação da resistência de aderência da peça de concreto sendo, portanto, de difícil determinação.

A engenharia estrutural tem sido campo de grande desenvolvimento, através da implementação e teste de novos modelos computacionais para prever as propriedades do



concreto. No caso de modelos comportamentais, o reconhecimento de padrões é de grande ajuda, e os métodos de inteligência computacional podem ser utilizados. Devido ao progresso computacional, que é refletido nas diversas atividades de pesquisa, tem-se muitas aplicações e tecnologias úteis. A inteligência artificial e suas aplicações são bons exemplos de campos explorados com expectativas variadas e resultados realistas. Dessa maneira, sistemas artificialmente inteligentes mostraram sua capacidade na resolução de problemas da vida real, particularmente em tarefas não lineares (Hoang *et al.* 2019).

Visando contribuir com o estudo da determinação das características do concreto, a partir de diferentes componentes, esse projeto visa, com a utilização de modelos computacionais como árvores de decisão e floresta randômica, viabilizar maneiras alternativas de determinar importantes características do concreto, utilizadas principalmente no dimensionamento de estruturas de concreto. Portanto, este projeto tem como foco a utilização de inteligência computacional na análise e no desenvolvimento de modelos de previsão da força de arrancamento em ensaios pull-out, a partir de métodos computacionais, enfatizando a precisão e a eficiência, bem como o seu potencial para lidar com dados experimentais.

## 2. ENSAIOS PULL-OUT

Em relação aos testes laboratoriais, verificou-se que um dos testes mais utilizados para avaliar a ligação de concreto-aço são os testes pull-out. Esse teste consiste em extrair uma barra de aço colocada no centro de um espécime de concreto cúbico. A força de arrancamento é medida em uma extremidade e o deslocamento é medido na outra extremidade, conforme Figura 1. Esse ensaio é padronizado pela RILEM/CEB (1983) onde é detalhado toda a sua execução.

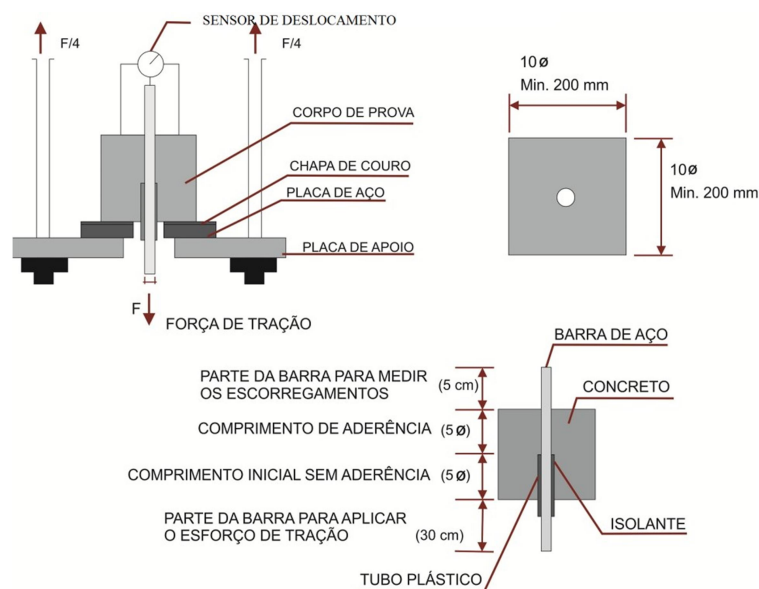


Figura 1: Ensaio de arrancamento Pull-Out Carvalho et al. (2017)

Conforme indicado na figura, o ensaio consiste em um corpo de prova cúbico de concreto, de dimensões  $10\phi \times 10\phi$  (sendo  $\phi$  o diâmetro da armadura) ou mínimo de  $20 \times 20$  cm, com uma barra de aço concêntrica que será submetida a uma força de tração, aplicada em passos de carga até atingir a ruptura por aderência. Na extremidade da barra de aço oposta a aplicação do carregamento, é posicionado um transdutor de deslocamentos e assim os dados obtidos do



ensaio são apresentados em valores de força e seus respectivos deslocamentos. no interior do corpo de prova, parte da barra é ancorada ao concreto e parte é isolada utilizando um tubo plástico. O comprimento de ancoragem recomendado é de  $5\phi$  (Miranda, 2018).

Conforme dito anteriormente, a falha de ligação das barras de aço nervuradas e entalhadas normalmente envolve dois fenômenos. O primeiro é caracterizado pelo esmagamento local do concreto que envolve as nervuras das barras e/ou a ruptura do concreto devido a rachaduras radiais ao redor da barra de aço. O esmagamento local acontece quando o confinamento proporcionado pelo concreto ao redor ou pela armadura transversal é grande e/ou a altura da nervura é pequena. Já a ruptura por fendilhamento ocorre quando o confinamento é pequeno e/ou a altura das nervuras presentes na barra de aço é grande. (Makni *et al.* 2014).

Em ensaios do tipo pull-out de barras finas nervuradas de aço a ruptura tende a ser por arrancamento, pois o confinamento das barras de aço tende a ser mais significativo, aumentando a resistência do bloco de concreto, dificultando a ruptura por fendilhamento. Nessas barras, a área relativa das nervuras desempenha um papel importante na resistência da ligação. A resistência de aderência com o concreto circundante é controlada principalmente pelo esforço confinante do concreto pelas nervuras presentes no aço. A falha, nesses casos, é sempre devida ao cisalhamento do concreto localizado entre as nervuras consecutivas, que então dependem da resistência do concreto (Makni *et al.* 2014).

### 3. MÉTODOS COMPUTACIONAIS

A árvore de decisão (DRT) é um algoritmo de aprendizagem supervisionada muito utilizado para problemas de classificação. Esse algoritmo funciona para variáveis categóricas e contínuas de entrada e saída. Na árvore de decisão, a população é dividida em dois ou mais conjuntos homogêneos (subpopulações) com base nos divisores/diferenciadores mais significativos das variáveis de entrada. Assim, a árvore de decisão identifica a variável mais representativa e os valores que retornam os conjuntos de população mais homogêneos.

A floresta de decisão aleatória (RFR), por sua vez, é uma poderosa técnica de aprendizagem em conjunto que é comumente usada em tarefas de classificação e regressão. Modelos de florestas aleatórias são gerados à partir da construção de uma coleção de árvores de decisão (Barandiaran, 1998).

Um dos maiores benefícios da floresta aleatória é poder lidar com dados de grandes volumes e com muitas dimensões. Esse algoritmo pode suportar milhares de variáveis de entrada e identificar as variáveis mais significativas, sendo por isso considerado um dos métodos de redução de dimensões. Outra vantagem das florestas aleatórias é a capacidade de estimar dados faltantes e manter a precisão quando uma grande parte dos dados estão faltando. Pode-se citar também a capacidade do modelo em equilibrar erros em conjuntos de dados onde as classes são desequilibradas. Outro aspecto importante refere-se também a uma amostragem dos dados de entrada com uma substituição chamada de amostragem *bootstrap*, onde um terço dos dados não é utilizado para o treinamento e pode ser usado para testes.

O maior problema das árvores de decisão é que elas tendem ao *overfitting* ou sobreajuste dos dados de treinamento. *Overfitting* é quando um modelo estatístico se ajusta tão bem ao conjunto de dados que se mostra ineficaz para prever novos resultados. A técnica mais comum usada para evitar esse tipo de problema é a redução por meio da poda de erros. Outra desvantagem refere-se ao fato que a floresta aleatória pode ser considerada como uma caixa preta para quem faz modelagem estatística. Nesse caso, o programador possui muito pouco





controle sobre o que é feito pelo algoritmo, podendo, na melhor das hipóteses, experimentar diferentes parâmetros no modelo.

A floresta aleatória é um excelente algoritmo para ser utilizado nos primeiros estágios de desenvolvimento de um modelo. Devido à sua simplicidade, é difícil construir uma floresta aleatória que não obtenha bons resultados.

#### 4. BASE DE DADOS

Para esse trabalho foi definida como base de dados principal a que se encontra disponível em Carvalho *et al* (2017). Esse estudo teve o objetivo de avaliar a performance de barras de aço com diâmetros menores de 10mm em ensaios de arrancamento. Nesse banco de dados estão disponíveis 89 amostras de testes experimentais e, para esse estudo, foram utilizados quatro parâmetros de entrada e um parâmetro de saída. Os parâmetros de entrada apresentam os seguintes componentes: resistência à compressão do concreto, diâmetro da barra de aço, comprimento de ancoragem, conformação superficial das barras. O único parâmetro de saída obtido experimentalmente é força de arrancamento em kN.

Além do pré-processamento, nesta base de dados foi realizada uma limpeza utilizando o cálculo do desvio padrão de cada amostra, separadas por diâmetro e resistência do concreto. Nessa análise, foram retirados valores considerados *outliers* para amostras que apresentaram um coeficiente de variação da força de arrancamento superior a 20%. Com isso, o banco de dados apresentou uma homogeneidade maior, contribuindo para resultados mais promissores na implementação dos métodos computacionais.

#### 5. RESULTADOS

##### 5.1. Árvores de decisão

Na Figura 2 e na Figura 3 são apresentados os valores originais e previstos para teste e treinamento, respectivamente, obtidos na implementação das árvores de decisão.

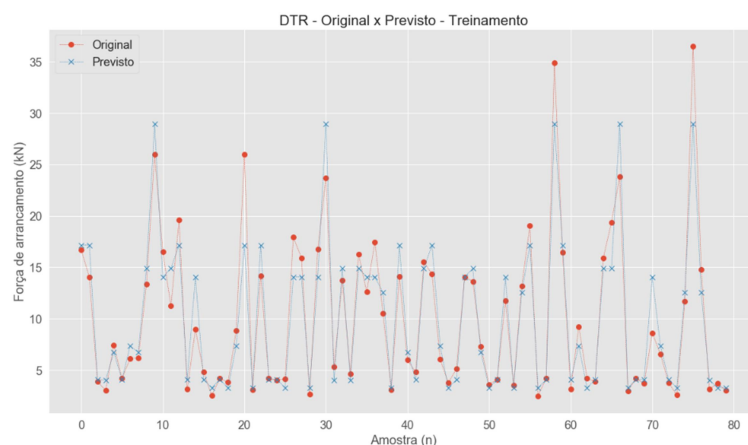


Figura 2: Resultados original *versus* previsto através da implementação das árvores de decisão para a parcela de treinamento

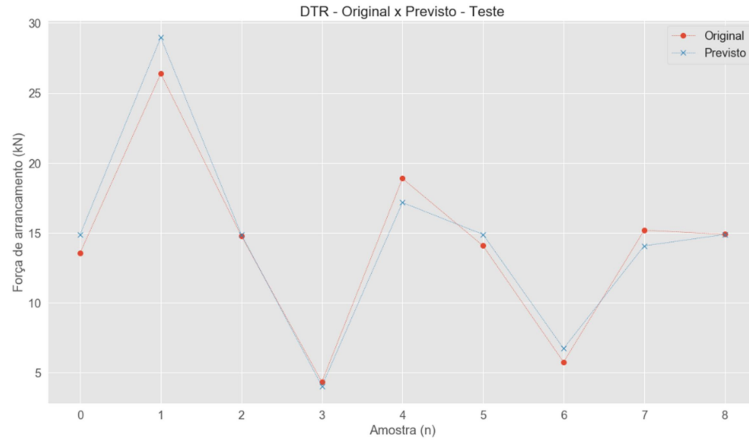


Figura 3: Resultados original *versus* previsto através da implementação das árvores de decisão para a parcela de teste

Na Figura 4 são apresentados os valores de  $R^2$  original *versus* previsto obtidos na implementação das árvores de decisão.




Figura 4: Resultados de  $R^2$  original *versus* previsto através da implementação das árvores de decisão para as parcelas de treinamento e teste

## 5.2. Floresta aleatória

Na Figura 5 e na Figura 6 são apresentados os valores originais e previstos para teste e treinamento, respectivamente, obtidos na implementação da floresta aleatória.

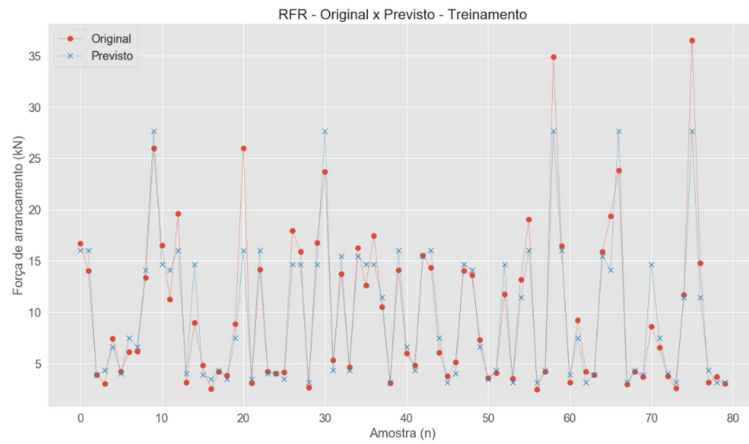


Figura 5: Resultados original *versus* previsto através da implementação da floresta aleatória para a parcela de treinamento



Figura 6: Resultados original *versus* previsto através da implementação da floresta aleatória para a parcela de teste

Na Figura 7 são apresentados os valores de  $R^2$  original *versus* previsto obtidos na implementação da floresta aleatória.




Figura 7: Resultados de  $R^2$  original *versus* previsto através da implementação da floresta aleatória para as parcelas de treinamento e teste



Os parâmetros de performance RMSE e  $R^2$  obtidos para a determinação da resistência à compressão do concreto são apresentados resumidamente na Tabela 1.

Tabela 1: Comparação dos resultados obtidos com a base de Carvalho *et al.*, (2017)

Método computacional	Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento $R^2$	Teste $R^2$
Árvores de decisão	2,40	1,26	0,89	0,95
Floresta aleatória	2,47	1,30	0,89	0,96

## 6. CONCLUSÃO

O objetivo principal desse trabalho consistiu em validar a utilização de métodos computacionais para auxiliar na determinação da força de arrancamento entre a barra de aço e o concreto, a partir de uma base de dados, sem a necessidade da utilização de ensaios destrutivos.

Com a apresentação desse trabalho foi possível concluir que os modelos computacionais apresentados podem auxiliar na determinação da força de arrancamento de barras de aço através de ensaios pull-out. Para as bases de dados de Carvalho *et al.* (2017), o modelo computacional com maior adaptabilidade foi o DTR (árvores de decisão). Também pode-se dizer que, para bases experimentais, ou seja, aquelas que ainda não foram pré-processadas e limpas, as técnicas de limpeza utilizadas, como o cálculo do desvio padrão de cada amostra, separadas por diâmetro e resistência do concreto, retirando os valores considerados outliers, ajudam na obtenção de melhores resultados.

## REFERÊNCIAS

- Barandiaran, I. (1998). The random subspace method for constructing decision forests. *IEEE Trans. Pattern Anal. Mach. Intell.*, v. 20, n. 8, p. 1–22.
- Barbosa, M. T. G. (2001). Avaliação do comportamento da aderência em concretos de diferentes classes de resistência,. Rio de Janeiro: UFRJ.
- Carvalho, E. P.; Ferreira, E. G.; da Cunha, J. C.; Rodrigues, C. de S.; Maia, N. da S. (2017). Experimental investigation of steel-concrete bond for thin reinforcing bars. *Latin American Journal of Solids and Structures*, v. 14, n. 11, p. 1932–1951.
- CEB, R. (1983) CEB/FIP Recommendations on reinforcement Steel for reinforced concrete. RC-6: Bond test for reinforcement Steel: 2. Pull-out test, Revised Edition.
- Hoang, N. D.; Tran, X. L.; Le, C. H.; Nguyen, D. T. (2019). A backpropagation artificial neural network software program for data classification in civil engineering developed in .NET framework. *DTU Journal of Science and Technology*, v. 03, n. 34, p. 51–56.
- Makni, M.; Daoud, A.; Karray, M. A.; Lorrain, M. (2014). Artificial neural network for the prediction of the steel-concrete bond behaviour. *European Journal of Environmental and Civil Engineering*, v. 18, n. 8, p. 862–881.
- Miranda, M. P. (2018). Avaliação experimental da influência das características do corpo de prova no ensaio de arrancamento (Pull-Out Test).
- Miranda, M. P.; Morsch, I. B.; Brisotto, D. de S.; Bittencourt, E.; Carvalho, E. P. (2021). Steel-concrete bond behavior: An experimental and numerical study. *Construction and Building Materials*, v. 271, p. 121918. Elsevier Ltd.