

AIPFRC: UMA PLATAFORMA INTELIGENTE PARA PREVISÕES DE PARÂMETROS DE PROJETO DE ESTRUTURAS DE BETÃO REFORÇADO COM FIBRAS



Fábio P. Figueiredo

Investigador
ISISE, Universidade do
Minho, Dep. Eng. Civil
Guimarães, Portugal
f.figueiredo@civil.uminho.pt



Joaquim A.O. Barros

Professor Catedrático
ISISE, Universidade do
Minho, Dep. Eng. Civil
Guimarães, Portugal
barros@civil.uminho.pt

SUMÁRIO

Nesse trabalho apresenta-se uma plataforma baseada em inteligência artificial, denominada AlpFRC (aipfrc.org), que tem como objetivo fornecer ferramentas inteligentes para auxílio no projeto de estruturas de Betão Reforçado com Fibras (BRF). Essas ferramentas são construídas utilizando-se algoritmos de aprendizagem de máquina treinados recorrendo a bases de dados com informações confiáveis de testes experimentais de BRF coletadas da literatura de forma inteligente usando técnicas de inteligência artificial e tratamento de dados.

Palavras-chave: Aprendizagem de máquina, Base de dados, Plataforma web, BRF, Resistência residual à flexão.

1. INTRODUÇÃO

Fibras curtas são utilizadas há décadas para aumentar a durabilidade e a resistência de estruturas de betão e substituir (parcial ou totalmente) armaduras convencionais. Ao adicionar fibras ao betão, como um constituinte extra da mistura, a resistência à tração pós-fissuração e a capacidade de absorção de energia podem ser melhoradas significativamente, com impacto favorável nas verificações do comportamento de estruturas de betão para estados limites de serviço e últimos (SLS e ULS, respetivamente).

O betão reforçado com fibras (BRF) é um material compósito caracterizado por uma matriz de cimento e fibras curtas de aço, polímero, carbono, vidro ou de materiais encontrados na

natureza e que requerem pouco tratamento. As propriedades do BRF dependem de vários aspectos, incluindo a geometria, fração volumétrica e propriedades mecânicas das fibras, a ligação entre as fibras e a matriz circundante e as propriedades mecânicas da matriz [1]. Este material compósito tem sido utilizado em uma variedade de aplicações como lajes apoiadas no solo [2], pavimentos [3], aduelas pré-fabricadas para túneis [4] [5] [6] [7], lajes apoiadas em estacas e pilares [8] [9] [10], pré-fabricação [11] [12], tabuleiros de pontes [13] e reabilitação estrutural [14] [15] [16] [17] [18].

As regras de projeto de estruturas de BRF são definidas em algumas normas, por exemplo, CEB-FIP Model Code [1] (doravante abreviado por MC2010), ACI 544 [19] e RILEM TC 162-TDF [20]. No projeto estrutural deste tipo de construções, para além das classes de desempenho definidas na regulamentação aplicável ao betão armado reforçado com armaduras convencionais, de que são exemplo as classes de resistência, exposição, tipo de estrutura, e trabalhabilidade do betão, o MC2010 propõe um conceito de classe de tenacidade para o BRF. Este conceito classifica a resistência pós-fissuração para BRF com base em parâmetros de resistência à tração à flexão residual, f_{Rj} , cujos valores são utilizados nas formulações para o projeto de estruturas de BRF e para definir as leis constitutivas a serem adotadas nas simulações numéricas com programas de computador baseados no método dos elementos finitos (MEF). Os f_{Rj} são obtidos através da execução de ensaios de flexão em vigas entalhadas de acordo com as recomendações da EN14651 [9]. A EN14651 estabelece que o ensaio de flexão em três pontos deve ser realizado em viga entalhada com comprimento mínimo de 550 mm, vão de 500 mm (L) e seção transversal de 150x150 mm (b×h). O entalhe deve estar localizado no meio da viga, resultando em uma altura efetiva de 125 mm (h_{sp}). O ensaio deve ser realizado até ser atingido uma abertura de 4 mm na boca do entalhe (CMOD). A Figura 1 mostra uma relação típica entre carga (F) e CMOD (CMOD) registado neste teste, a partir da qual é determinado:

$$f_{Rj} = \frac{3 F_j L}{2 b h_{sp}^2} \quad (1)$$

onde F_j é a força correspondente a CMOD_j ($j=1$ a 4) igual a 0,5, 1,5, 2,5 e 3,5 mm. De acordo com o MC2010, a classe de tenacidade de um BRF é classificada por #X, onde # é o valor característico de f_{R1} em MPa (f_{R1k}), enquanto X é uma letra que define um intervalo para f_{R3k}/f_{R1k} . Por exemplo, 4c é um BRF com $f_{R1k} \in [4 - 5[$ MPa e $f_{R3k}/f_{R1k} \in [0.9 - 1.1[$.

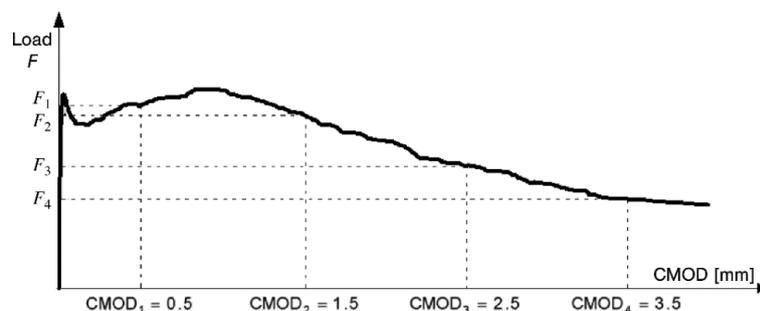


Figura 1. Exemplo de curva F-CMOD obtida em ensaio segundo as recomendações da EN14651 [9].

O f_{R1} é a resistência residual à tração em flexão para um $CMOD1=0,5mm$, e tem uma influência significativa nas verificações de projeto para as condições SLS, sendo a largura de fissura e a flecha máxima de um membro estrutural de BRF tanto menores quanto maior for f_{R1} [21]. Por sua vez, a resistência residual à tração em flexão para um $CMOD3=2,5mm$, f_{R3} , tem um impacto significativo nas verificações de projeto para condições ULS, aumentando a capacidade de carga dos elementos estruturais em BRF e a ductilidade de seus modos de rotura, principalmente as estruturas com apoios redundantes do ponto de vista de equilíbrio estático [21] [10]. Assim, é muito importante desenvolver metodologias de projeto de misturas racionais e confiáveis para BRF que assegurem os valores alvos de f_{Rj} , os quais são dependentes das exigências estruturais da aplicação em causa. Algumas iniciativas no uso de algoritmos de inteligência artificial (IA) [22] [23] já foram propostas, mas é fundamental avaliar seu desempenho e capacidade preditiva e, para isso, é essencial ter uma base de dados com resultados experimentais confiáveis.

Com este objetivo, os autores do presente trabalho iniciaram o desenvolvimento de uma plataforma para reunir mais informações sobre composições BRF e resultados obtidos em ensaios experimentais que caracterizem o mais completamente possível o seu comportamento mecânico (durabilidade e sustentabilidade são também ambições para esta iniciativa, mas em fases subsequentes). O principal objetivo desta iniciativa é coletar dados de BRF para serem considerados por algoritmos de IA para geração de informações para um amplo espectro de intervenientes no uso desses compósitos, especialmente para produtores, projetistas e investigadores. Uma plataforma baseada na web (aipfrc.org) foi desenvolvida para esse fim e está disponível para essas comunidades. A plataforma é suportada por ferramentas de inteligência artificial para alimentação contínua e dinâmica da base de dados e avaliação da sua consistência.

O principal objetivo deste artigo é apresentar essa plataforma, tendo na presente fase sido dada prioridade às previsões de f_{Rj} devido à sua relevância para o projeto de estruturas de BRF.

Do ponto de vista do projeto de estruturas de BRF, esta plataforma pode ser extremamente útil, pois pode-se estimar uma composição de BRF que assegure uma determinada classe de tenacidade; ou, propondo uma determinada composição de BRF, pode-se estimar a classe de tenacidade correspondente.

2. METODOLOGIA

O desenvolvimento de uma ferramenta para a previsão do f_{Rj} de BRF baseada em técnicas de IA começa por escolher, entre uma variedade de algoritmos, qual deles pode produzir melhores previsões. No entanto, essa tarefa não é simples e depende de muitos fatores, como tamanho e tipo de dados, número de recursos, precisão, custo computacional, entre outros. De forma sucinta, pode-se definir a aprendizagem de máquina (AM) como uma técnica baseada na utilização de algoritmos programados que aprendem a fazer previsões analisando os dados de entrada. É comum categorizar os algoritmos de AM por seu estilo de aprendizado como supervisionado, não supervisionado e semi-supervisionado. Este trabalho concentra-se apenas em alguns dos algoritmos de aprendizado de máquina

supervisionados mais usados. No aprendizado supervisionado, os algoritmos aprendem a fazer previsões a partir de um conjunto de dados de entrada, geralmente designados por dados de treinamento. O algoritmo usa o conjunto de dados de treinamento para aprender a mapear as variáveis de entrada para variáveis de saída e, eventualmente, prever os valores de saída de novos dados de entrada com certa precisão. A precisão das previsões é medida pelas métricas adotadas.

A metodologia considerada neste trabalho compreendeu: i) a coleta de f_{Rj} da literatura dedicada a determinar experimentalmente esses dados; ii) preparação de dados e avaliação do desempenho preditivo de algoritmos de AM supervisionados; iii) implementação de modelos de AM utilizando as bibliotecas Scikit-Learn [24] e Keras [25].

2.1 Base de dados

A base de dados utilizada neste estudo contém um total de 212 conjuntos coletados da literatura. Considerando que as fibras de aço com extremidades dobradas foram as mais utilizadas em aplicações estruturais de BRF, o conjunto de dados é, na atual fase, limitado ao betão reforçado com fibra de aço (BRFA) deste tipo, mas os autores pretendem estender as funcionalidades da plataforma para betões reforçados com outros tipos de fibras. Embora o número de registos na base de dados pareça pequeno e não adequado para previsões precisas, é suficiente para avaliar as potencialidades de cada algoritmo de AM. Para obter boas previsões usando conjuntos de dados experimentais relativamente reduzidos, alguns investigadores têm utilizado diferentes técnicas, como o caso de combinar dados reais e sintéticos para ampliar esse conjunto de dados [22]. No entanto, os autores adotaram uma abordagem um pouco diferente para avaliar as potencialidades dos algoritmos de AM, usando apenas dados reais e implementando uma estratégia em que o melhoramento do desempenho do modelo é efetuado de forma automática à medida que a plataforma baseada na web coleta mais dados.

O conjunto de dados de entrada compreende quatro características, isto é, variáveis independentes usadas como entrada em algoritmos de AM, nomeadamente: resistência à compressão média do betão (f_c , em MPa, teor de fibras (C_f , em kg/m^3), diâmetro da fibra (d_f , em mm, comprimento da fibra (l_f , em mm); e dois alvos, ou seja, valores de saída: valor médio da resistência residual à tração em flexão correspondente a $\text{CMOD1} = 0,5$ mm (f_{R1}) e a $\text{CMOD3} = 2,5$ mm (f_{R3}). A faixa de valores da base de dados coletada é: f_c : 22-98 MPa; C_f : 10-160 kg/m^3 ; d_f : 0.20-1.05 mm; l_f : 13-80 mm.

2.2 Análise Exploratória de Dados

A Análise Exploratória de Dados (EDA) refere-se ao processo crítico de realizar investigações iniciais sobre dados para descobrir padrões, extrair variáveis importantes, detetar outliers e anomalias com a ajuda de estatísticas e representações gráficas. Evitar esta etapa pode levar, por exemplo, a modelos imprecisos ou modelos precisos treinados com dados errados.

Em uma primeira etapa procedeu-se à deteção de valores atípicos ou outliers. Outliers são pontos de dados que diferem significativamente do restante dos dados. Eles podem indicar

um erro dos resultados/ensaios experimentais ou podem ser devidos à variabilidade intrínseca à entidade medida. Os algoritmos de IA são suscetíveis às características estatísticas da base de dados, como é o caso da distribuição das variáveis de entrada. Dados atípicos podem prejudicar e enganar o processo de treinamento, resultando em modelos menos precisos, tempos de treinamento mais longos e resultados deficientes. Os outliers foram detetados e removidos da base de dados usando um algoritmo baseado na regra do intervalo interquartil.

Posteriormente, determinou-se a correlação entre atributos individuais e correlação de dados. A relação entre dois atributos individuais (ou variáveis) e sua distribuição são mostradas na Figura 2. Esta figura evidencia, tal como já tinha sido apontado por alguns investigadores [26], que existe uma forte relação linear entre f_{R1} e f_{R3} . Verifica-se ainda uma tendência dessas variáveis aumentarem com f_c e C_f .

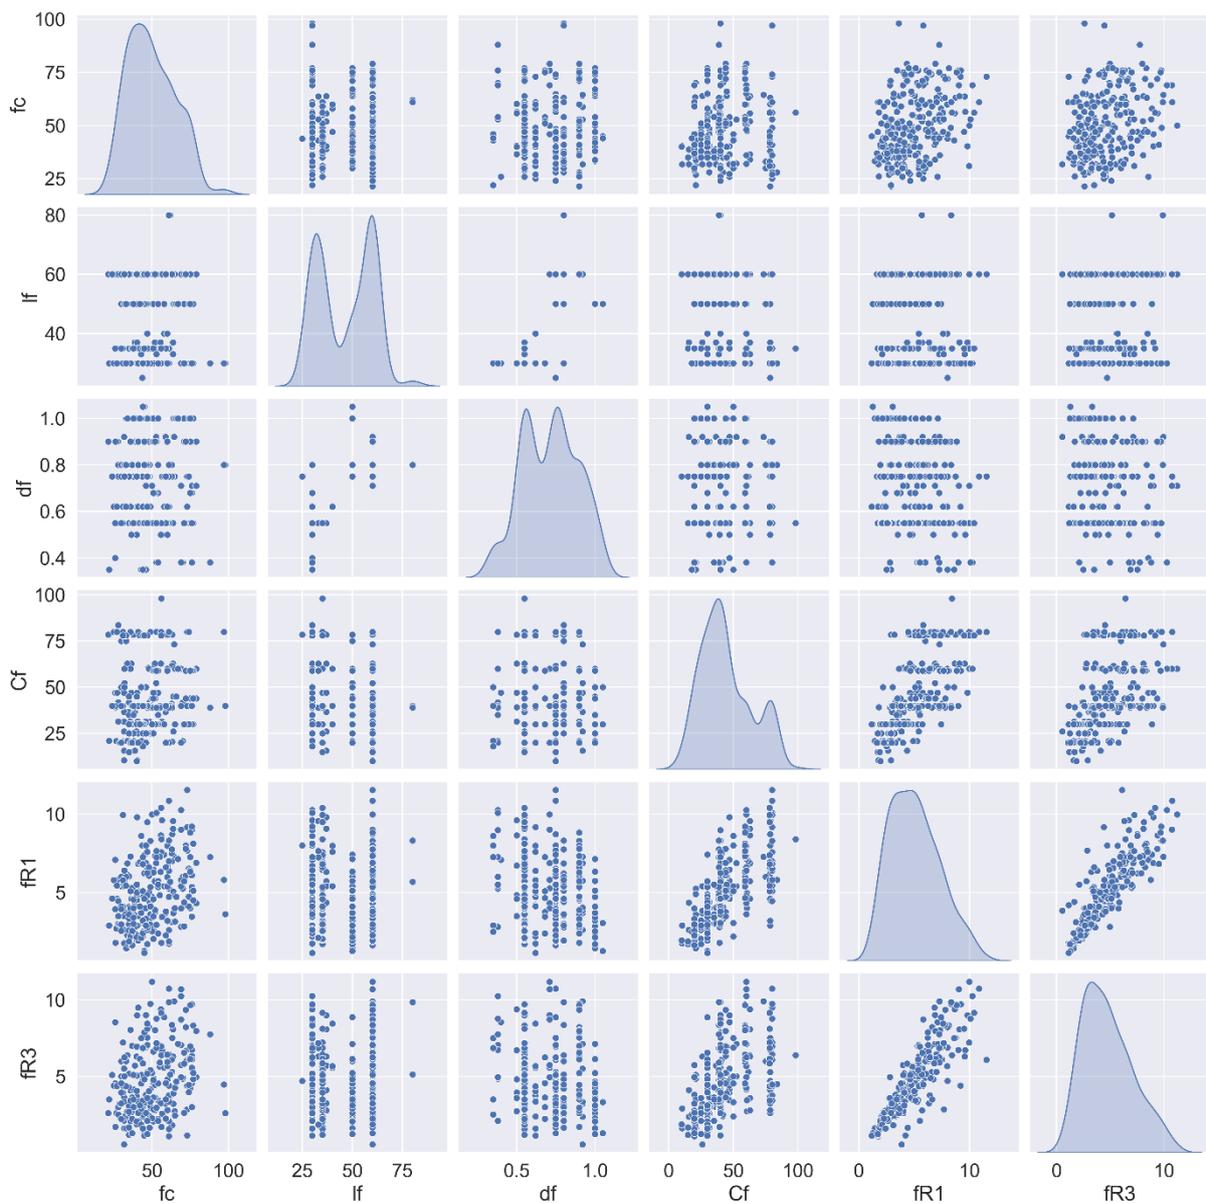


Figura 2. – Distribuições das variáveis (unidades: l_f e d_f em mm; C_f em kg/m^3 e f_c , f_{R1} , f_{R3} em MPa).

A Figura 3 mostra a correlação entre as variáveis de entrada. Este mapa evidencia a relevância das variáveis na análise de regressão, quantificando a relação entre duas variáveis por meio do coeficiente de correlação de Pearson. Esse coeficiente varia de -1 a +1, onde -1 indica uma correlação linear negativa perfeita, o que significa que quando uma variável aumenta, a outra diminui, enquanto +1 indica uma correlação linear positiva perfeita entre duas variáveis, o que significa igual tendência de variação dessas variáveis. Finalmente, 0 indica que não há correlação linear, o que significa que as variáveis mudam de maneira aleatória em relação umas às outras. O coeficiente entre as variáveis f_{R1} e f_{R3} é 0,86, mostrando que elas estão fortemente correlacionadas positivamente. Existe uma forte correlação positiva entre l_f e d_f (0,72), que está relacionada às condições tecnológicas de produção das fibras de aço consideradas. O teor de fibras, C_f , também é um fator importante no projeto de BRF, uma vez que f_{Rj} aumenta com C_f devido ao maior número de fibras que atravessam as fissuras, oferecendo resistência à sua abertura e promovendo a formação de fissuras de menor largura [27]. Isso explica a boa correlação de C_f com as variáveis f_{R1} e f_{R3} , de 0,67 entre C_f e f_{R1} e 0,49 entre C_f e f_{R3} , o que indica que o teor de fibras tem mais influência na limitação de aberturas de fissuras relativamente pequenas (até 0,5mm) do que para aberturas de fissuras maiores (2,5mm). O mapa mostra ainda que f_c tem menor impacto na resistência residual do que C_f , com coeficiente de 0,34 e 0,30 para f_{R1} e f_{R3} respectivamente.

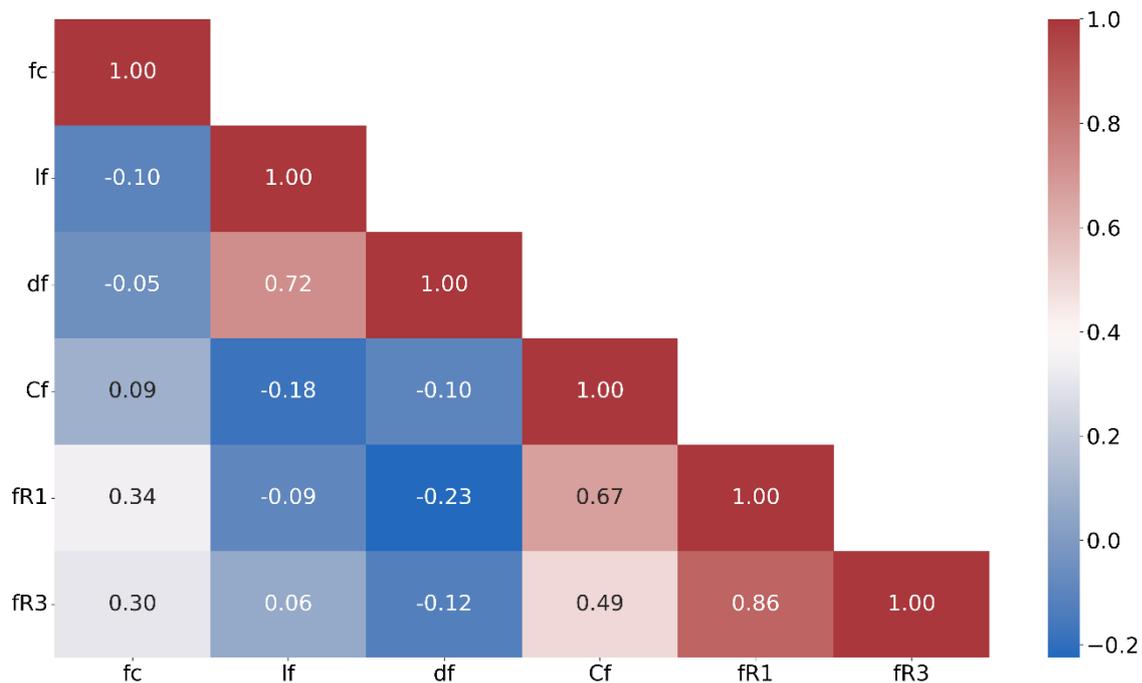


Figura 3. Mapa de correlação.

2.3 Algoritmos de Aprendizagem de Máquina

Na previsão do f_{R1} e f_{R3} dos BRFs foram utilizados alguns dos algoritmos de aprendizagem de máquina (AM) mais populares. Os algoritmos de AM foram agrupados em famílias de acordo com suas semelhanças e funções. Foram considerados seis grupos de algoritmos de AM: Modelos Lineares (*Linear Regression - LR* e *Ridge Regression - RR*), Máquinas de

Vetores de Suporte (*Support Vector Machines - SVM*), Vizinhos Mais Próximos (*K-Nearest Neighbours - KNN*), Árvores de Decisão (*Decision Trees - DTR*), Métodos de Ensemble (*Random Forests - RF* e *Gradient Boosting - GB*) e Rede Neural (*Multilayer perceptron - MLP*).

Os hiperparâmetros em um modelo de aprendizagem de máquina são valores definidos antes do treinamento do modelo, não sendo afetados pelo processo de treinamento, mas melhoram a qualidade e a velocidade do treinamento. Por exemplo, o número de camadas ocultas, o valor da taxa de aprendizado, número de lotes, entre outros, são hiperparâmetros de uma rede neural artificial. Os hiperparâmetros de cada algoritmo de AM estudado foram moderadamente otimizados, ou seja, um conjunto de valores de hiperparâmetros foi ajustado para encontrar os valores ideais de cada algoritmo que, potencialmente, resultariam em previsões mais "precisas".

A Figura 4 apresenta o desempenho dos modelos desenvolvidos na previsão de f_{R1} e f_{R3} , utilizando a raiz do erro quadrático médio (RMSE) de ambos os valores como métrica, e a abordagem de validação cruzada. O erro RMSE é definido por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

onde y o valor real da variável e \hat{y} o valor estimado pelo modelo preditivo.

Para cada modelo, o erro RMSE foi calculado em cada iteração da validação cruzada, o qual se encontra representado nesta figura. As linhas horizontais inferiores e superior de cada *box plot* correspondem aos valores de erro mínimo e máximos obtidos na análise de validação cruzada; a linha horizontal dentro de cada caixa representa o valor mediano das pontuações em todas as iterações. A análise da Figura 4 revela que os melhores resultados foram obtidos com o modelo MLP, uma vez que apresentou o menor RMSE entre todos os modelos.

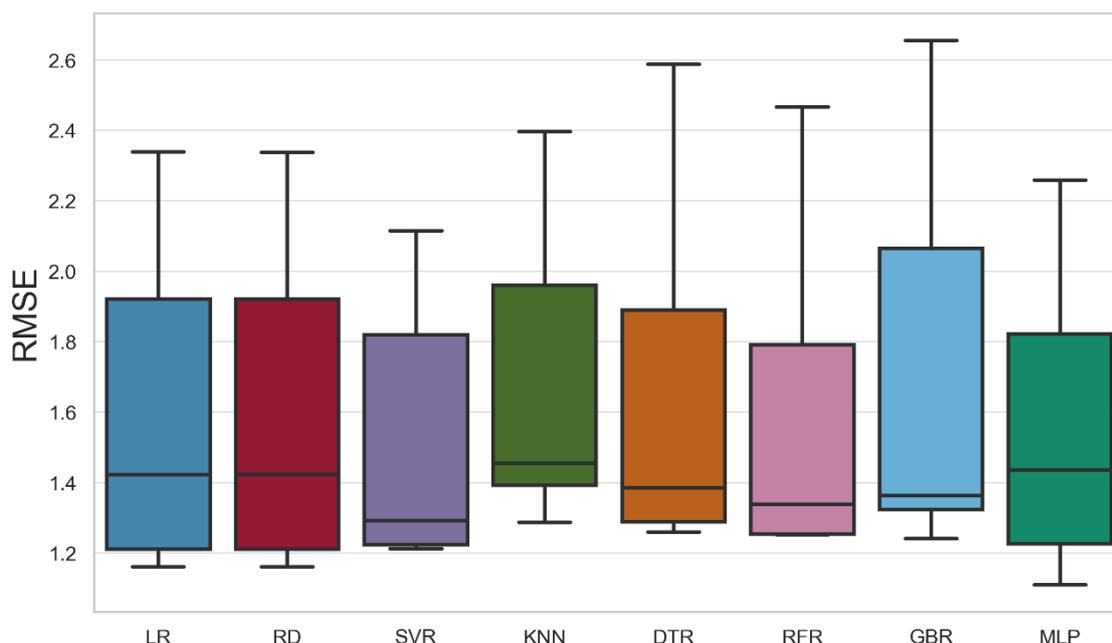


Figura 4. Comparação entre modelos de IA avaliados. RMSE em MPa.

3. PLATAFORMA BASEADA EM INTELIGÊNCIA ARTIFICIAL

As necessidades e resultados deste estudo motivaram o lançamento de uma aplicação baseada na web, Figura 5, dedicada à recolha de informação sobre misturas de BRF e ao fornecimento de ferramentas para ajudar na conceção de estruturas de FRC. O melhor modelo ML desenvolvido neste estudo (MLP) foi integrado na aplicação como uma ferramenta para prever a resistência residual à tração por flexão de provetes preparados por diferentes composições de BRF.

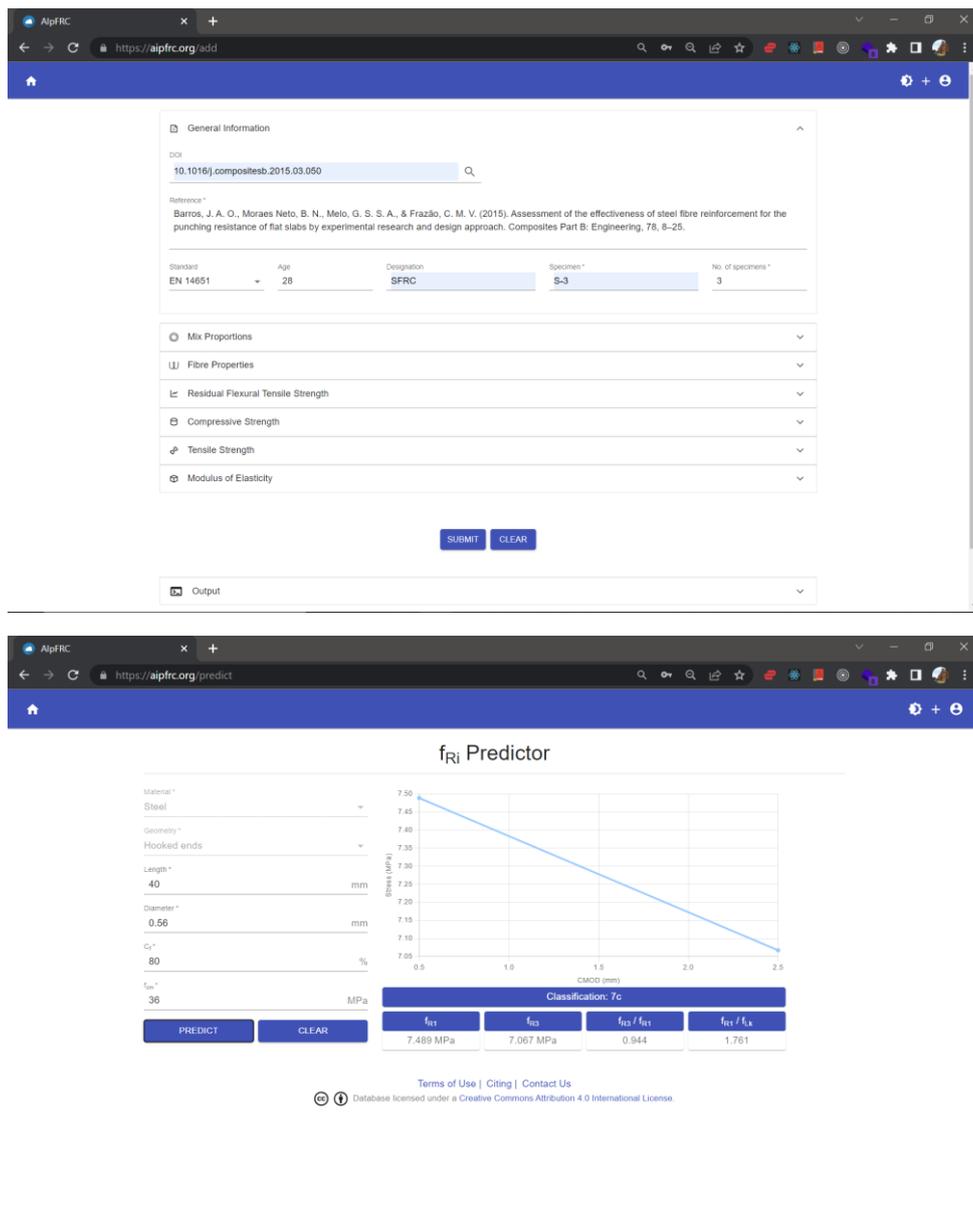


Figura 5. Plataforma AlpFRC (aipfrc.org). a) Formulário para entrada na base de dados de dados relativos a ensaios b) Aplicação para previsão de f_{Ri} .

A plataforma é uma aplicação baseada na web (ou aplicação web), ou seja, um software de aplicação que corre num servidor. Portanto, pode ser acedida através de uma ligação de rede, e não é necessária qualquer instalação. Os utilizadores podem aceder à aplicação web utilizando qualquer navegador web. Uma grande vantagem deste tipo de aplicação é que pode ser acedida através de várias plataformas, tais como um computador de secretária, portátil ou móvel. Também permite o acesso de vários utilizadores à mesma versão da aplicação.

A plataforma é suportada por algoritmos de inteligência artificial capazes de analisar e processar os dados em tempo real, a fim de garantir a fiabilidade dos dados. A Figura 6 resume sucintamente o fluxo de trabalho típico da plataforma. (1) O utilizador adiciona novos dados ao sistema; (2) Os dados são guardados na base de dados; (3) O sistema verifica a consistência dos dados; (4) O modelo ML é treinado usando o novo conjunto de dados; (5) O utilizador recebe as previsões do modelo ML atualizado.

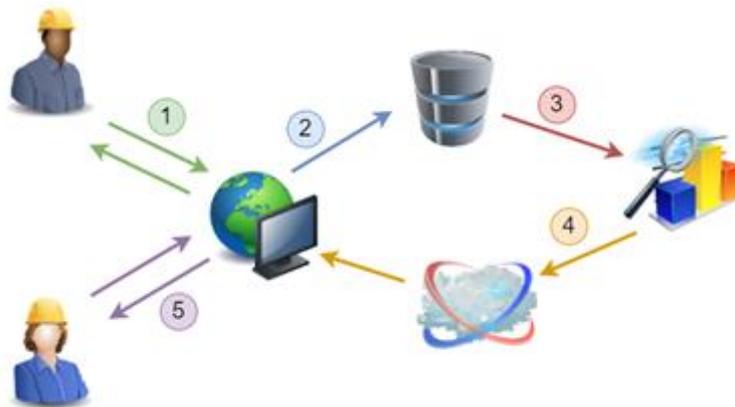


Figura 6. Representação do fluxo de trabalho da plataforma AlpFRC.

Uma vez que o treinamento do modelo de AM pode levar algum tempo para ser concluído, o sistema executa as etapas (3) e (4) somente quando há dados suficientes disponíveis, ou seja, o processo de treinamento é iniciado automaticamente somente quando uma certa quantidade de novos dados está disponível. Durante a etapa (3) são realizadas verificações para garantir que os dados são confiáveis. As verificações são realizadas usando dois métodos, o primeiro em que a consistência dos dados é submetida a verificações simples baseadas na comparação com formulações analíticas e/ou informações coletadas de outras fontes. No segundo método de verificação, os dados de entrada são comparados automaticamente com os dados relatados em sua referência de origem. Este método baseia-se no facto de que, se a referência foi revisada por pares, há uma chance mínima de os dados publicados não serem confiáveis. O segundo método está atualmente em desenvolvimento e seu objetivo é usar técnicas de IA para extrair e tratar as informações relevantes das referências de origem e compará-las com os dados de entrada fornecidos pelo utilizador.

Na primeira fase, é realizado um conjunto de verificações baseadas em formulações analíticas recomendadas pelos códigos de projeto. Para cada novo dado adicionado ao banco de dados, a plataforma verifica sua consistência calculando os valores da resistência à tração do betão e módulo de elasticidade de acordo com o código de projeto especificado

pelo utilizador, e comparando se os valores fornecidos pelo utilizador estão próximos dos valores calculados a menos de uma tolerância, inicialmente admitida como 25%. O conjunto de verificações inclui a relativa à resistência à compressão do betão (f_c) fornecida, impedindo o fornecimento de informação com f_c inferior ao recomendado para aplicações estruturais.

Dados, como as propriedades da fibra, que não possuem expressão analítica para comparação direta, são verificados com base nas informações coletadas de outras fontes, por exemplo, experiência, dados da literatura, fichas técnicas de fabricação, entre outros e apoiados por técnicas de IA. A plataforma calcula a esbelteza da fibra (l_f/d_f) e compara-a com valores mínimos e máximos determinados com base nos tipos de fibra disponíveis no mercado. A rotina de verificação também verifica se a resistência à tração e o módulo de elasticidade das fibras estão dentro de uma faixa de valores esperados de acordo com o tipo de material da fibra.

Caso os dados não passem na etapa de verificação, o sistema coloca os dados em quarentena para posterior verificação. Os dados em quarentena serão totalmente analisados usando o segundo método de verificação e, caso sejam aprovados nesta fase, os dados são libertados da quarentena. Este processo garante que o conjunto de dados seja sempre confiável.

A plataforma é dividida em três módulos principais: interface AlpFRC, banco de dados e API principal. A interface permite que o utilizador interaja com a aplicação. O banco de dados armazena todos os dados da aplicação. A API principal é onde toda a lógica por trás da aplicação é implementada, incluindo todos os algoritmos de IA.

4. CONCLUSÕES

Este artigo avaliou o desempenho de alguns dos algoritmos de IA mais populares para prever a resistência residual à tração por flexão de BRF. O desempenho dos algoritmos de aprendizagem de máquina foi avaliado usando o método de validação cruzada. Um conjunto de dados contendo 212 ensaios de flexão foi utilizado para o treinamento e validação dos modelos desenvolvidos. Também se apresentou uma nova plataforma baseada na web, chamada AlpFRC, dedicada a coletar dados e fornecer ferramentas para aplicações de BRF. Na presente fase, a base de dados inclui apenas valores de betão reforçado com fibras de aço de extremidades dobradas.

Os resultados mostraram que o melhor desempenho foi obtido utilizando o algoritmo Multilayer Perceptron (MLP). O modelo MLP final treinado produziu uma precisão preditiva de $RMSE = 1.571 MPa$ e desvio padrão, $SD = 0.421 MPa$. A precisão desse modelo será aprimorada à medida que novos dados forem adicionados ao conjunto de dados de treinamento e o modelo for atualizado. No entanto, a precisão obtida é bastante aceitável, pois há uma dispersão superior a 20% nos ensaios de flexão devido à pequena área de superfície de fratura e influência da distribuição e orientação das fibras [28].

A plataforma está disponível em aipfrc.org, onde os utilizadores têm acesso ao banco de dados e todas as ferramentas disponíveis para aplicações de BRF. Na fase atual, apenas a

ferramenta para previsões de f_{Rj} está disponível. No entanto, mais ferramentas para auxiliar no projeto de estruturas de BRF serão integradas à plataforma no futuro. Os autores esperam que esta plataforma se torne uma referência para as comunidades científicas e da indústria da construção no futuro. No entanto, a colaboração de todos os utilizadores é crucial para o sucesso desta iniciativa.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro concedido pela Fundação para a Ciência e a Tecnologia (FCT) através do projeto FemWebAI com referência PTDC/ECI-EST/6300/2020.

REFERÊNCIAS

- [1] fib-federation internationale du beton, “fib Model Code for Concrete Structures 2010,” John Wiley & Sons, 2013.
- [2] S. Nayar and R. Gettu, “Comparison of different design methodologies for FRC slabs-on-grade,” in Proceedings of the 9th RILEM International Symposium on Fiber Reinforced Concrete (BEFIB 2016), 2016.
- [3] A. Nobili, L. Lanzoni and A. Tarantino, “Experimental investigation and monitoring of a polypropylene-based fiber reinforced concrete road pavement,” *Constr. Build. Mater.*, vol. 47, pp. 888-895, 2013.
- [4] R. Gettu, B. Barragán, T. García, G. Ramos, C. Fernández and R. Oliver, “Steel fiber reinforced concrete for the Barcelona metro line 9 tunnel lining,” in Proceedings of the 6th International RILEM Symposium on Fibre-Reinforced Concretes (FRC) (BEFIB 2004), Varenna, 2004.
- [5] A. Caratelli, Z. R. A. Meda and P. Romualdi, “Structural behaviour of precast tunnel segments in fiber reinforced concrete,” *Tunn. Undergr. Space Technol.*, vol. 26, pp. 284-291, 2011.
- [6] G. Tiberti, F. Minelli and G. Plizzari, “Reinforcement optimization of fiber reinforced concrete linings for conventional tunnels,” *Compos. B. Eng.*, vol. 58, pp. 199-207, 2014.
- [7] S. Carmona, C. Molins, A. Aguado and F. Mora, “Distribution of fibers in SFRC segments for tunnel linings,” *Tunn. Undergr. Space Technol.*, vol. 51, pp. 238-249, 2016.
- [8] B. Parmentier, P. V. Itterbeeck and A. Skowron, “The flexural behaviour of SFRC flat slabs: the Limelette full-scale experiments for supporting design model codes,” in Proceedings of the FRC 2014 Joint ACI-fib International Workshop, Montréal, 2014.
- [9] BS EN 14651:2005+A1:2007 Test method for metallic fibre concrete. Measuring the flexural tensile strength (limit of proportionality (LOP), residual)
- [10] A. Nogales and A. d. I. Fuente, “Numerical-aided flexural-based design of fibre reinforced concrete column-supported flat slabs,” *Eng. Struct.*, vol. 232, p. 111745, 2021.
- [11] A. d. I. Fuente, R. Escariz, A. d. Figueiredo and A. Aguado, “Design of macro-synthetic fiber reinforced concrete pipes,” *Constr. Build. Mater.*, vol. 43, pp. 523-532, 2013.
- [12] T. Soetens, “Design Models for the Shear Strength of Prestressed Precast Steel Fibre Reinforced Concrete Girders,” Belgium, 2015.
- [13] J. Gonilha, J. Barros, J. Correia, J. Sena-Cruz, F. Branco, L. Ramos, D. Gonçalves, M. Alvim and T. Santos, “Static, dynamic and creep behaviour of a full-scale GFRP-SFRSCC hybrid footbridge,” *Composite Structures Journal*, vol. 118, pp. 496-509, 2014.

- [14] G. Martinola, A. Meda, G. A. Plizzari and Z. Rinaldi, "Strengthening and repair of RC beams with fiber reinforced concrete," *Cement & Concrete Composites*, vol. 32, pp. 731-739, 2010.
- [15] M. K. H. N. M. Hussein, "Strength and ductility of RC beams strengthened with steel- reinforced strain hardening cementitious composites," *Cement & Concrete Composites*, vol. 34, no. 9, pp. 1061-1066, 2012.
- [16] H. Baghi and J. Barros, "Shear strengthening of reinforced concrete T-beams with Hybrid Composite Plate," *Composites for Construction Journal*, vol. 20, no. 6, 2016.
- [17] D. V. A. K. B. K. F.A. Farhat, "High performance fibre-reinforced cementitious composite (CARDIFRC) – Performance and application to retrofitting," *Engineering Fracture Mechanics*, vol. 74, pp. 151-167, 2007.
- [18] D. Vachon and B. Massicotte, "Seismic retrofitting of rectangular bridge piers with FRC jakets," in 6th RILEM Symposium on Fibre-Reinforced Concrete (FRC), Varenna, 2004.
- [19] ACI Committee 544, "Guide to Design with Fiber-Reinforced Concrete," ACI, 2018.
- [20] RILEM TC 162-TDF, "Final recommendation of RILEM TC 162-TDF: Test and design methods for steel fibre reinforced concrete," *Materials and Structures*, vol. 36, no. 262, pp. 560-567, 2003.
- [21] H. Salehian, J. Barros and M. Taheri, "Evaluation of the Influence of Post-Cracking Response of Steel Fibre Reinforced Concrete (SFRC) on Load Carrying Capacity of SFRC Panels," *Construction and Building Materials Journal*, vol. 73, pp. 289-304, 2014.
- [22] M. Congro, V. M. d. A. Monteiro, A. L. Brandão, B. F. d. Santos, D. Roehl and F. d. A. Silva, "Prediction of the residual flexural strength of fiber reinforced concrete using artificial neural networks," *Construction and Building Materials*, vol. 303, p. 124502, 2021.
- [23] T. Ikumi, E. Galeote, P. Pujadas, A. d. I. Fuente and R. López-Carreño, "Neural network-aided prediction of post-cracking tensile strength of fibre-reinforced concrete," *Computers & Structures*, vol. 256, p. 106640, 2021.
- [24] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot and E. Duchesnay, "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825--2830, 2011.
- [25] F. Chollet and others, *Keras*, 2015.
- [26] J. Barros, V. Cunha, A. Ribeiro and J. Antunes, "Post-Cracking Behaviour of Steel Fibre Reinforced Concrete," *RILEM Materials and Structures Journal*, vol. 38, no. 275, pp. 47-56, 2005.
- [27] J. Lee, B. Cho and E. Choi, "Flexural capacity of fiber reinforced concrete with a consideration of concrete strength and fiber content," *Construction and Building Materials* , vol. 138 , p. 222–231, 2017.
- [40] S. J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 3 ed., New Jersey: Pearson, 2009.