



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE RUSSAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

FRANCISCO LUCAS DE OLIVEIRA FREIRE

**UMA ABORDAGEM BASEADA EM DADOS PARA A PREDIÇÃO DA
RESISTÊNCIA AO CISALHAMENTO DE VIGAS DE CONCRETO ARMADO
REFORÇADAS COM EB-FRP**

RUSSAS

2026

FRANCISCO LUCAS DE OLIVEIRA FREIRE

UMA ABORDAGEM BASEADA EM DADOS PARA A PREDIÇÃO DA RESISTÊNCIA
AO CISALHAMENTO DE VIGAS DE CONCRETO ARMADO REFORÇADAS COM EB-
FRP

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil na Universidade Federal do Ceará, como requisito obrigatório à obtenção do título de Mestre.
Área de pesquisa: Modelagem computacional e Inteligência Artificial

Orientador: Prof. Dr. Jerfson Moura Lima.
Co-Orientador: Prof. Dr. Jonathas Iohanathan Felipe de Oliveira

RUSSAS

2026

FRANCISCO LUCAS DE OLIVEIRA FREIRE

UMA ABORDAGEM BASEADA EM DADOS PARA A PREDIÇÃO DA RESISTÊNCIA
AO CISALHAMENTO DE VIGAS DE CONCRETO ARMADO REFORÇADAS COM EB-
FRP

Dissertação apresentada ao Programa de Pós-
Graduação em Engenharia Civil na
Universidade Federal do Ceará, como requisito
obrigatório à obtenção do título de Mestre.
Área de pesquisa: Modelagem computacional e
Inteligência Artificial

Aprovada em 20/02/2026.

BANCA EXAMINADORA

Prof. Dr. Jerfson Moura Lima (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Jonathas Iohanathan Felipe de Oliveira (Co-Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Iago Freitas de Almeida
Universidade Federal do Ceará (UFC)

Prof. Dr. Manoel José Mangabeira Pereira Filho
Universidade Federal do Pará (UFPA)

Prof. Dr. Eduardo Morais de Medeiros
Universidade Federal Rural do Semi-Árido (UFERSA)

AGRADECIMENTOS

A pandemia de Covid-19 foi um período marcante na história de muitas pessoas. Na minha, em particular, foi o gatilho que forçou uma série de mudanças profundas. O adoecimento mental, seguido dos diagnósticos de depressão e transtorno de ansiedade generalizada, tornou-se o maior obstáculo da minha carreira acadêmica.

Em vários momentos, pensei em desistir: da graduação, do mestrado, de um possível doutorado e, até mesmo, da vida. Sentir os dias passarem sem realmente vivê-los é uma das maiores dores e angústias que alguém pode experimentar. A comida perde o sabor, o mundo perde a cor e o que antes trazia felicidade torna-se apenas parte de mais um dia comum. Mesmo enfrentando tudo isso, concluí minha graduação em Engenharia Civil.

As batalhas, porém, não acabaram na colação de grau. Aos 45 do segundo tempo, decidi me inscrever no processo seletivo para o mestrado acadêmico e, para minha surpresa, fui aprovado em primeiro lugar. Após o início das aulas, a vontade de desistir revisitou-me muitas vezes. O sentimento de incapacidade, a comparação com os colegas e a síndrome do impostor foram constantes. Fico feliz por ter resistido. O mestrado me ensinou que, mesmo com poucos recursos financeiros e humanos, sou capaz de realizar muito - inclusive, concluir esta etapa.

Neste momento, gostaria de agradecer imensamente a... mim. Agradeço por, mesmo atravessando dias tão sombrios, nunca ter desistido. Por acreditar, como Stephen Hawking, que enquanto há vida, há esperança. Por continuar caminhando, mesmo quando eu queria estar correndo. Afinal, o sentido da vida é para frente.

Tive também o privilégio de conhecer pessoas incríveis nessa caminhada. Agradeço à minha mãe, Joana Darc, a pessoa mais gentil desse mundo. Aos meus irmãos, Leo e Jonas, exemplos de determinação. Às minhas tias, Rita e Alvani, pela alegria e autenticidade. À minha tia Valdete, ao meu padrinho Edvan e aos meus primos, Pedro Lucas e Edvan Filho.

Aos meus grandes amigos: Daniel Brito, Allan Magalhães, Elói Romão, Carlos Eduardo e Lucas Leite. Às minhas psicólogas, Caroline Cristino e Geise Bernardo, por todo apoio que me deram, desde a graduação até o mestrado.

Aos meus orientadores, Jerfson Lima e Jonathas Oliveira, e aos professores Alexandre Arruda e Esequiel Mesquita.

Por fim, agradeço o apoio financeiro da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) e da Secretaria de Ciência, Tecnologia e Educação Superior do Ceará (Secitece), fundamentais para a realização desta pesquisa.

RESUMO

O uso de polímero reforçado com fibra (FRP, do inglês *fiber reinforced polymer*) tem se consolidado como uma solução promissora no reforço de estruturas de concreto, devido a propriedades notáveis como durabilidade, leveza, resistência à corrosão e rapidez de instalação. Entretanto, a aplicação desse material enfrenta desafios por ser um método relativamente recente, sobretudo no que tange ao reforço ao cisalhamento, à otimização de projetos e ao desenvolvimento de modelos precisos para a predição da resistência. Nesse cenário, publicações recentes sobre o uso de aprendizado de máquina têm demonstrado potencial para superar esses entraves, embora ainda existam limitações como a escassez de dados de referência e a necessidade de modelos robustos que capturem a complexidade do comportamento real das estruturas. Diante do exposto, este estudo teve como objetivo propor modelos de prescrição de resistência ao cisalhamento de vigas de concreto armado reforçadas com FRP colado externamente utilizando modelos de regressão linear e redes neurais artificiais. Como etapas fundamentais da pesquisa, construiu-se um amplo banco de dados a partir de trabalhos experimentais, abrangendo diferentes cenários de reforço. Por meio de estudo estatístico, realizou-se a redução da dimensionalidade do problema, identificando os parâmetros físicos mais significativos e desenvolvendo modelos matemáticos de regressão linear múltipla para a predição da resistência ao cisalhamento. Ademais, empregando técnicas de aprendizado de máquina, desenvolveu-se uma Rede Neural Artificial (RNA) e a otimização dos hiperparâmetros do modelo base. O melhor modelo linear apresentou um erro absoluto médio até 66,97% menor que as normativas internacionais ($R^2 = 0,74$). Na etapa de otimização dos hiperparâmetros e aplicação de técnicas de regularização no modelo base de RNA, obtiveram-se modelos preditivos com desempenho significativamente superior às normativas existentes, com um coeficiente de determinação na ordem de 0,90. A aplicação da regularização LASSO resultou em um modelo com máxima capacidade de generalização e consistência física, alcançando um R^2 de 0,92 em testes cegos. No geral, os modelos desenvolvidos apresentaram um bom desempenho na predição da resistência ao cisalhamento, com potencial de aplicação em trabalhos práticos e futuras investigações.

Palavras-chave: aprendizado de máquina; concreto armado; polímero reforçado com fibra; reforço ao cisalhamento.

ABSTRACT

The use of Fiber-Reinforced Polymer (FRP) has become established as a promising solution for strengthening concrete structures due to its remarkable properties, such as durability, lightweight, corrosion resistance, and speed of installation. However, the application of this material faces challenges as it is a relatively recent method, particularly regarding shear strengthening, design optimization, and the development of accurate models for strength prediction. In this context, recent publications on the use of machine learning have demonstrated the potential to overcome these hurdles, although limitations such as the scarcity of reference data and the need for robust models that capture the complexity of real structural behavior still exist. Given this background, this study aimed to propose strength prediction models for externally bonded FRP-strengthened reinforced concrete beams using linear regression models and artificial neural networks (ANN). As fundamental stages of the research, a comprehensive database was constructed from experimental studies, covering various strengthening scenarios. Through statistical analysis, dimensionality reduction was performed, identifying the most significant physical parameters and developing multiple linear regression mathematical models for shear strength prediction. Furthermore, employing machine learning techniques, an ANN was developed along with the optimization of the base model's hyperparameters. The best-performing linear model presented a mean absolute error up to 66.97% lower than international codes, with a coefficient of determination (R^2) of 0.74. In the hyperparameter optimization and regularization stage of the base ANN model, predictive models were obtained with performance significantly superior to existing standards, reaching an R^2 in the order of 0.90. The application of LASSO regularization resulted in a model with maximum generalization capacity and physical consistency, achieving an R^2 of 0.92 during blind testing.

Keywords: machine learning; strength prescription; fiber-reinforced polymer; FRP-strengthened beams.

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Justificativa	12
1.2	Objetivos.....	13
1.3	Objetivos específicos.....	14
2	REFERENCIAL TEÓRICO	15
2.1	Polímeros reforçados com fibras (FRP)	15
2.2	Reforço de vigas ao cisalhamento com FRP	17
2.3	Modelos normativos para predição da resistência ao cisalhamento.....	18
2.3.1	<i>ACI 440.2R - 2017</i>	18
2.3.2	<i>Fib Bulletin 14</i>	21
2.3.3	<i>Fib Bulletin 90</i>	24
2.4	Regressão Linear Múltipla	28
2.5	Inteligência Artificial	29
2.5.1	<i>Aprendizado de máquina</i>	29
2.5.2	<i>Redes Neurais Artificiais</i>	30
2.5.3	<i>Técnicas de regularização</i>	33
2.5.4	<i>Verificação de desempenho</i>	34
3	ESTADO DA ARTE	36
3.1	Reforço ao cisalhamento de vigas de concreto armado com FRP	38
3.2	Modelos de prescrição da resistência ao cisalhamento	40
3.3	Aplicação de ferramentas de IA e <i>machine learning</i> para prescrição da resistência ao cisalhamento.....	42
4	METODOLOGIA	45
5	BANCO DE DADOS	47
6	ESTUDO ESTATÍSTICO	52
6.1	Seleção de variáveis significativas.....	56
6.2	Análises de regressão de variáveis	58
6.3	Acurácia do modelo proposto.....	63
6.4	Discussão dos resultados obtidos via regressão	65
7	MODELO DE REDES NEURAS ARTIFICIAIS	68
7.1	Ajuste dos hiperparâmetros da RNA	69
7.2	Otimização da Topologia da Rede Neural	77

7.3	Análise de sensibilidade com regularização L1	80
7.3.1	Regularização L1 (LASSO) com variáveis selecionadas.....	81
7.3.2	Regularização L1 (LASSO) com todas as variáveis	83
7.4	Discussão dos resultados obtidos via RNA.....	85
8	CONCLUSÃO	89
8.1	Sugestões de trabalhos futuros.....	90
	REFERÊNCIAS	92

1 INTRODUÇÃO


O reforço de estruturas de concreto armado se torna necessário em diversas situações, como em estruturas existentes que foram projetadas conforme antigas diretrizes ou considerando apenas as cargas permanentes; elementos sujeitos à deterioração, como danos acidentais, má manutenção, danos devido a ações sísmicas e corrosão (Rahman; Arafin; Muntasir Billah, 2023a). Além disso, ele pode se tornar necessário em casos na qual há uma mudança na finalidade da edificação, conseqüentemente, alterando o seu carregamento acidental.

Nessa perspectiva, a demolição e correspondente substituição de elementos estruturais são dispendiosas, juntamente com interrupções nas atividades realizadas na edificação. Assim, é muito importante adotar uma estratégia de *retrofit* e reforço mantendo a estrutura funcionando tanto quanto possível (Rahman; Arafin; Muntasir Billah, 2023a). Dentre as técnicas usuais, tem-se o uso de polímeros reforçados por fibra (FRP, do inglês *fiber reinforced polymer*) para reforçar estruturas de concreto armado danificadas ou aumentar sua capacidade resistente, devido as suas características de excelente durabilidade, alta versatilidade, leveza com alta resistência, natureza não corrosiva e ser de rápida instalação. Embora apresente baixa resistência à altas temperaturas e ser de difícil execução em superfícies irregulares, esse material tem apresentado grande potencial na sua utilização como reforço estrutural.

Dentre os usos possíveis do FRP para reforço de estruturas, pode-se citar o reforço de vigas à flexão, ao cisalhamento e à torção; reforço de pilares; e reforço da ligação viga-pilar; além de carregamentos explosivos, cíclicos, sísmicos e estruturas incendiadas e sujeitas a altas temperaturas. Tal método se torna especialmente importante quando consideradas as vigas, devido serem elementos prevalentes nas estruturas de concreto armado, bem como possuem modo de ruptura por cisalhamento frágil, fazendo com que o seu colapso resulte em grandes danos (Mohammadi, Amirhossein; Barros; Sena-Cruz, 2023). A utilização desse material pode ser feita por meio da colagem externamente ao elemento estrutural (EB-FRP, do inglês *externally bonded FRP*) ou inserido próximo à superfície (NSM-FRP, do inglês *near-surface mounted FRP*), conforme ilustrado na Figura 1. No reforço colado externamente, sua eficiência é diretamente dependente da aderência entre o FRP e a superfície de concreto, em que os esforços são transmitidos pela resina responsável por manter os elementos unidos. Por outro

lado, no caso do reforço NSM, o FRP é embutido no elemento estrutural, no qual a união entre os elementos é realizada por meio de uma resina polimérica ou argamassa.

Figura 1 - Reforço estrutural com EB-FRP e NSM-FRP.



Fonte: Elaborado pelo autor.

À medida que o reforço com FRP tem ganhado popularidade na reparação de estruturas de concreto, é necessário um procedimento de projeto confiável para obter o máximo benefício das propriedades do FRP e aumentar a longevidade das vigas. Ademais, comparado ao reforço por flexão, o reforço por cisalhamento é mais complexo e tem atraído atenção, pois a ruptura por cisalhamento é repentina, em razão de seu comportamento frágil (Oliveira *et al.*, 2024; Rahman; Arafin; Muntasir Billah, 2023a). Diretrizes de projeto, como ACI 440.2R-17 (ACI, 2017) e fib 14 (FIB BULLETIN 14, 2001), são amplamente praticadas no projeto de sistemas de reforço de FRP. No entanto, a precisão da estimativa da capacidade de cisalhamento por estas diretrizes ainda é baixa (Rahman; Arafin; Muntasir Billah, 2023a), embora nos últimos anos tenham sido realizados numerosos estudos experimentais relativos ao cisalhamento de vigas usando FRP (Bukhari *et al.*, 2013; Chen; Teng; Chen, 2013b; Oller *et al.*, 2015; D'Antino;

Triantafillou, 2016; Naderpour; Alavi, 2017; Oller Ibars *et al.*, 2018); Oller; Kotynia; Marí, 2021; Oliveira *et al.*, 2024.

Contudo, os modelos de previsão formulados podem carecer de precisão quando são aplicados a situações em que não foram tão exploradas nos programas experimentais que compõem os dados que foram utilizados para desenvolver os modelos, como diferentes geometrias e tipos de carregamentos. Uma parte considerável dos modelos desenvolvidos segue a premissa de que a capacidade de cisalhamento última de uma viga de concreto armado reforçada externamente com FRP é a soma das contribuições de cisalhamento máximas do concreto, do aço e do reforço. Isso foi afirmado por G. M. Chen *et al.*(2013b) em seus estudos acerca da interação das armaduras de cisalhamento interna e externa em vigas de concreto armado reforçadas, com FRP colado nas faces laterais da viga, ou nas faces laterais e inferior. Os autores verificaram uma melhora nos resultados do seu modelo de resistência ao cisalhamento com a consideração de um fator de interação, quando comparado a outros modelos.

As conclusões de G. M. Chen *et al.*(2013b) também foram constatadas por Taghipour Anvari; Babanajad; Gandomi, (2023) com seus estudos acerca do desenvolvimento de modelos de previsão a partir de programação genética (*genetic programming*). Nesse trabalho, foi verificado que os dois modelos propostos apresentaram uma precisão significativa, quando comparado a outros modelos existentes na literatura, e adequados para uso em projetos de engenharia.

Além disso, a simplificação de que a resistência ao cisalhamento máxima do elemento consiste na soma das contribuições de seus componentes julga que a capacidade máxima de cisalhamento é atingida sem que um componente falhe antes do outro, de forma a desconsiderar qualquer forma de interação de cisalhamento entre os diferentes componentes de resistência (Abuodeh; Abdalla; Hawileh, 2020; Chen, G. M.; Teng; Chen, 2013b; Wang, Chenxin *et al.*, 2023a). Devido a isso, os modelos teóricos não correspondem às situações reais, o que pode resultar em valores de resistência excessivamente altos em determinados casos (Kar; Biswal, 2020). Por isso, para a utilização do reforço com FRP de forma eficiente e econômica, torna-se necessário o desenvolvimento de ferramentas mais precisas e confiáveis, que descrevam de forma eficaz a contribuição do FRP na resistência ao cisalhamento do elemento reforçado.

Na literatura, existem bancos de dados disponíveis, favorecendo o desenvolvimento de fórmulas de previsão para estimativa de resistência ao cisalhamento de vigas CA adaptadas

com FRP (Chen, J. F.; Teng, 2003; Perera, R *Et al.*, 2010; Perera, Ricardo; Arteaga; Diego, 2010; Sayed; Wang; Wu, 2013). Isso se torna necessário para que seja possível desenvolver projetos mais assertivos, considerando o fator técnico (dimensionamento de reforços que suportem as solicitações); econômico e sustentável, por meio da utilização de materiais mais eficientes e menor consumo de recursos naturais, alinhando com os tópicos 9, 11 e 12 dos Objetivos de Desenvolvimento Sustentável (ODS) definidos pela Organização das Nações Unidas (ONU).

Recentemente, pesquisadores têm utilizado o aprendizado de máquina (AM) para prever a resistência final ao cisalhamento do elemento reforçado, bem como a contribuição do FRP, como os estudos realizados por Oliveira *et al.*, (2024), Tanarslan; Secer; Kumanlioglu, (2012) e Wang, C. *et al.*, (2023a). Contudo, embora esses estudos apresentem resultados promissores, há desafios quando a utilização de algoritmos de AM que necessitam serem investigados, como a existência de bancos de dados limitados; precisão insuficiente, dependente, sobretudo, de inconsistências nos dados utilizados; e a dificuldade de obtenção de uma equação, a partir do modelo de AM, que descreve o comportamento dos dados (WANG, CHENXIN *et al.*, 2023a).

1.1 Justificativa

As vigas de concreto armado estão entre os componentes estruturais mais recorrentes na engenharia civil, integrando os mais diversos sistemas construtivos. No entanto, tais elementos são suscetíveis ao surgimento de fissuras, à redução da capacidade resistente ou até à colapso estrutural, em função de fatores como carregamentos excessivos, deterioração ambiental, envelhecimento dos materiais e danos por ações sísmicas (Z. Wang *et al.*, 2025) (Rahman *et al.*, 2023). Nesse cenário, a insuficiência na resistência ao cisalhamento configura-se como um problema crítico pois, ao contrário da ruptura por flexão, apresenta baixa ductilidade, podendo resultar em falhas frágeis e catastróficas (Mohammadi, Amirhossein; Barros; Sena-Cruz, 2025).

Sob essa perspectiva, o reforço estrutural atua com o objetivo de prolongar a vida útil das vigas de concreto armado e elevar sua capacidade de carga e durabilidade. Dentre as alternativas disponíveis, o reforço com polímeros reforçados com fibras colados externamente (EB-FRP) destaca-se como uma das soluções mais eficientes para incrementar a resistência ao cisalhamento e a ductilidade desses elementos. A resistência ao cisalhamento resultante dessa

intervenção é tipicamente estimada por modelos empíricos ou semiempíricos, bem como diretrizes normativas. No entanto, a precisão desses métodos na predição da resistência ao cisalhamento ainda é considerada insuficiente (Rahman; Arafin; Muntasir Billah, 2023b), uma vez que, segundo Mohammadi, Amirhossein; Barros; Sena-Cruz, (2025), há complexas relações não lineares entre a capacidade resistente e os parâmetros geométricos e mecânicos da viga e do reforço, além das incertezas inerentes à natureza frágil e brusca das falhas por cisalhamento.

Diante disso, as técnicas de aprendizado de máquina têm sido empregadas para prever a capacidade resistente final do elemento reforçado. Diversos pesquisadores investigaram a aplicação dessa abordagem no desenvolvimento de modelos substitutos capazes de prever a resistência ao cisalhamento dos elementos reforçados, obtendo resultados promissores com o emprego de diferentes técnicas de aprendizado supervisionado. Visto que algoritmos de aprendizado de máquina apresentam níveis distintos de acurácia em função de suas diferentes arquiteturas, torna-se imperativo comparar múltiplos modelos para selecionar a abordagem mais adequada. Nesse contexto, a otimização de hiperparâmetros é fundamental para elevar a precisão preditiva e a eficiência computacional do modelo adotado (Yuan *et al.*, 2022). Dentre as abordagens para esse ajuste, destacam-se os métodos de busca manual e busca automática.

Visto que algoritmos de aprendizado de máquina apresentam níveis distintos de acurácia, a comparação sistemática de diferentes arquiteturas e a otimização de hiperparâmetros são etapas cruciais para garantir que o modelo não apenas decore os dados, mas compreenda a física do problema. Assim, este trabalho justifica-se pela necessidade de converter a complexidade do comportamento do reforço estrutural de EB-FRP em uma ferramenta preditiva robusta, promovendo projetos de reforço mais seguros, econômicos e sustentáveis, alinhando a inovação tecnológica da Ciência de Dados às demandas críticas da Engenharia Estrutural.

1.2 Objetivos

Este trabalho tem como objetivo propor modelos de prescrição de resistência ao cisalhamento de vigas de concreto armado reforçadas com FRP colado externamente utilizando modelos de regressão linear e redes neurais artificiais.

1.3 Objetivos específicos

Os objetivos específicos desse estudo são:

- a) Desenvolver um banco de dados composto por vigas de seção retangular e T reforçadas por diferentes tipos de FRP nas configurações colado lateralmente, reforço em U e envolvido completamente ensaiadas à ruptura ao cisalhamento a partir de estudos experimentais da literatura.
- b) Avaliar a acurácia das normativas em prever a resistência ao cisalhamento de vigas de concreto armado reforçadas com FRP.
- c) Determinar os parâmetros mais influentes no carregamento último das vigas reforçadas por meio de análises de correlação.
- d) Desenvolver um modelo via regressão linear múltipla, capaz de, a partir das variáveis mais influentes, prever a resistência ao cisalhamento de vigas reforçadas com FRP.
- e) Desenvolver um modelo de RNA e realizar um estudo paramétrico para otimização dos hiperparâmetros e topologia da rede.

2 REFERENCIAL TEÓRICO

A resistência ao cisalhamento de vigas de concreto armado por si só é um fenômeno complexo, considerando também a sua falha de natureza frágil. Contudo, quando associado ao reforço com FRP, um material compósito de comportamento difícil de modelar analiticamente ou numericamente, o problema se torna ainda mais desafiante. No contexto de reforço de vigas utilizando esse método, a ausência de normativas definitivas, bem como a complexidade de aplicação dos métodos analíticos para predição de resistência ao cisalhamento de elementos reforçados com esse material, compromete a assertividade dos projetos de reforço estrutural, considerando todas as restrições de aplicação e análise impostas.

Por outro lado, o desenvolvimento de ferramentas computacionais baseadas em inteligência artificial, aliado aos exaustivos trabalhos experimentais desenvolvidos no meio científico nas últimas décadas para análise desse tipo de reforço, apresentam potencialidades cuja aplicação deve ser explorada na resolução de problemas atuais na área da engenharia civil. Nessa perspectiva, conciliar os conhecimentos e avanços de diferentes áreas possibilitarão encarar a dinâmica dos sistemas de reforço estrutural com FRP sob um olhar inovador e sustentável, uma vez que esta pesquisa estará, também, alinhada com os tópicos 9, 11 e 12 dos ODS.

Nessa perspectiva, este item apresentará a base teórica necessária para a compreensão e desenvolvimento desta pesquisa. Abordando, inicialmente, as características relativas ao reforço ao cisalhamento de vigas de concreto armado com FRP e, posteriormente, uma discussão acerca de alguns dos métodos normativos e da literatura para a predição da resistência de elementos reforçados. Ademais, também será apresentada os conceitos de inteligência artificial e aprendizado de máquina, com ênfase nos algoritmos que serão explorados nesse estudo.

2.1 Polímeros reforçados com fibras (FRP)

Os primeiros usos de polímeros e compósitos se deu durante a Segunda Guerra Mundial, com a fabricação de radomos para proteção de equipamentos eletrônicos e componentes de aeronaves, sobretudo utilizando a fibra de vidro (Khodadadi *et al.*, 2024). Contudo, apenas a partir de 1960 que esses materiais começaram a ser explorados na indústria da construção civil.

Conforme apresentado por Hollaway, (1993), houve duas estruturas importantes no desenvolvimento deste material na construção: a estrutura de cúpula erguida em 1968 em Benghazi; e a estrutura do telhado no Aeroporto de Dubai construída em 1972, cujas unidades foram projetadas e construídas no Reino Unido. Entre 1970 e 1980, outras edificações notáveis foram construídas no Reino Unido, como *Morpeth School*, *Mondial House* (a Sede do GPO em Londres), *Covent Garden Flower Market* e o *American Express Building, Brighton*.

Entretanto, apenas no início da década de 1990, em razão da crescente necessidade de manutenção e renovação de edificações e infraestruturas, que o FRP começou a ser utilizado para fins de reforço estrutural. A Ponte Ibach em Lucerna, na Suíça, foi a primeira ponte do mundo a ser reforçada com polímero reforçado com fibra carbono (CFRP), restaurada em 1991,

O uso de FRP para o reforço estrutural surgiu para suprir a necessidade urgente do fortalecimento de estruturas atribuído a fatores diversos, como mau desempenho da estrutura, mudança de utilização da edificação, erros de projeto e cargas excepcionais, como aquelas provocadas por terremotos e sismos. Devido as suas características notáveis particulares, seu uso tem ganhado destaque por ser superior a reforços antigos, como aumento de seção de concreto e placas metálicas, visto sua praticidade de aplicação e economia (Panahi; Zareei; Izadi, 2021).

De acordo com o Manual de Reforço das Estruturas de Concreto Armado com Fibras de Carbono (Machado, 2010), disponibilizado pela empresa Viapol, esses materiais compósitos compreendem dois componentes principais: a matriz polimérica, responsável por manter as fibras coesas e transferência dos esforços; e o elemento estrutural, que absorve as tensões decorrentes dos esforços solicitantes.

A durabilidade desses materiais poliméricos é influenciada por diversos fatores, e as propriedades do material (como tipos de fibra e matriz de resina) podem afetar diretamente o desempenho do FRP (Harle, 2024), além de fatores como as dimensões e características mecânicas das fibras, a taxa de fibra em relação à matriz, entre outros. Os materiais mais utilizados na fabricação das fibras dos FRP são o carbono, vidro, basalto e aramida, cujas propriedades típicas são apresentadas na Tabela 1. Dentre esses materiais, o carbono é mais utilizado em virtude de seu módulo de elasticidade elevado, alta resistência à tração e durabilidade.

Tabela 1 - Propriedades típicas das fibras utilizadas no FRP e de aço; e comparação com o aço estrutural.

Tipo de fibra	Material	Módulo de Young (GPa)	Resistência à tração (MPa)	Deformação específica de ruptura (%)
Carbono	Alta resistência	215-235	3500-4800	1,4-2,0
	Ultra alta resistência	215-235	4800-6000	2,0-2,3
	Alto módulo	350-500	2500-3100	0,5-0,9
	Ultra alto módulo	500-700	2100-2400	0,2-0,4
Vidro	Tipo “E”	70	1900-3000	3,0-4,5
	Tipo “S”	85-90	3500-4800	4,5-5,5
Aramida	Baixo módulo	70-80	3500-4100	4,3-5,0
	Alto módulo	155-130	3500-4000	2,5-3,5
Basalto	-	90	2500-3200	3,0-3,5
Aço	-	185	3070	1,7
-	Aço estrutural	200	400	25*

* Deformação específica de escoamento de 0,2%

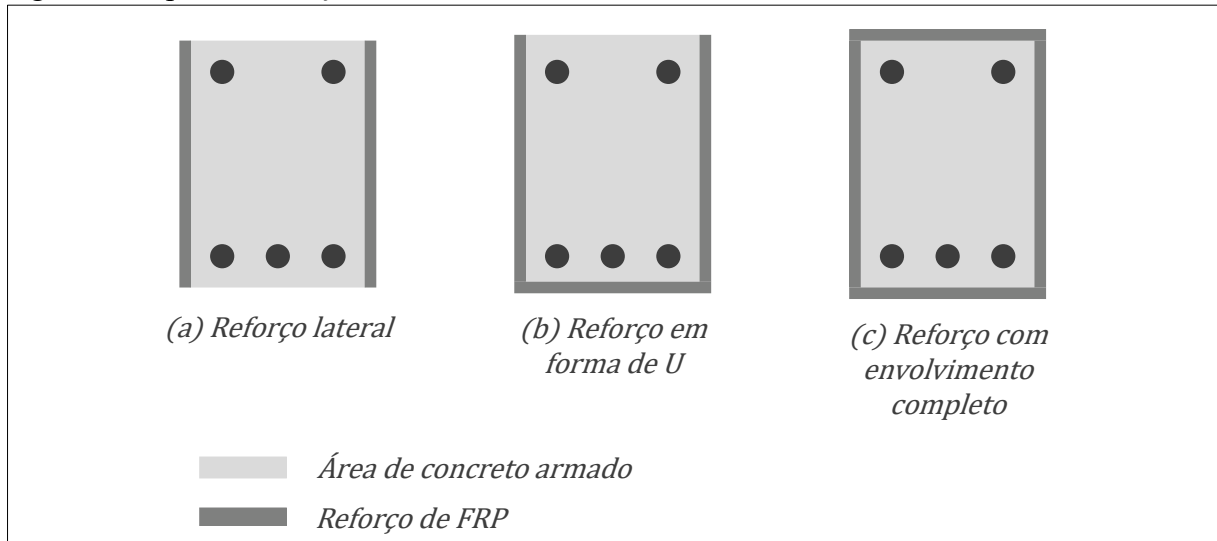
Fonte: Oliveira (2024).

2.2 Reforço de vigas ao cisalhamento com FRP

O reforço ao cisalhamento com EB-FRP pode ser realizado em diferentes configurações: manta ou laminados colados lateralmente nas seções do elemento; manta e laminados colados nas faces laterais e na face inferior (em forma de U); e manta para envolvimento completo da seção (Figura 2).

A configuração do reforço por envolvimento completo (Figura 2-c) é o método mais eficaz, contudo, caso a viga esteja conectada a laje, essa solução nem sempre é economicamente viável devido à necessidade de demolições e recomposições localizadas na laje, para permitir que sejam feitas aberturas no concreto para a passagem da fibra para a realização do envolvimento completo da seção. Nessas situações, o reforço em “U” (Figura 2-b), que compreende três faces da viga, é geralmente utilizada quando a viga está conectada à laje, sendo mais efetivo em regiões onde há momentos positivos em razão de retardar o início do processo de fissuração do concreto por tração (Machado, 2010).

Figura 2 - Tipos de reforço ao cisalhamento com EB-FRP.



Fonte: Elaborado pelo autor.

Por fim, o reforço lateral (Figura 2-a) é utilizado quando for possível aderir a fibra apenas nas faces laterais da viga. Embora seja considerada a solução menos eficiente, a sua aplicação ainda oferece um ganho de resistência ao elemento. Uma das formas de melhorar o desempenho dessa configuração é a adoção de dispositivos de ancoragem para melhorar o contato entre a fibra e a interface de concreto, bem como evitar o modo de falha do sistema por descolamento da fibra.

2.3 Modelos normativos para predição da resistência ao cisalhamento

Atualmente, algumas das diretrizes existentes, como ACI 440.2R-17 (ACI, 2017), fib Bulletin 14, (2001) e fib Bulletin 90 (Balázs *et al.*, 2019), consideram a contribuição do reforço de FRP na resistência ao cisalhamento do elemento reforçado. Segundo apresentado por Oller; Kotynia; Marí, (2021), tais formulações são semelhantes à contribuição do reforço transversal interno para a resistência ao cisalhamento, baseada na analogia da treliça, com a diferença de que o reforço de FRP não escoou.

2.3.1 ACI 440.2R - 2017

A abordagem apresentada na ACI 440.2R-17 (ACI, 2017) baseia-se na analogia da treliça de Morsch e foi desenvolvida por Khalifa *et al.*, (1998), onde a resistência ao cortante é dada pela soma das contribuições do concreto (V_c), armadura internas (V_s) e a armadura externa de FRP (V_f), conforme a Equação 2.1. O coeficiente ψ_f representa a incerteza quanto ao reforço

com FRP, tendo como valores recomendados $\psi_f=0,95$ para reforços com envolvimento completo e $\psi_f=0,85$ para reforço em “U” ou lateral.

$$V_n = V_c + V_s + \psi_f V_f \quad \text{Equação 2.1}$$

As parcelas de resistência advindas do concreto e do aço são obtidas conforme a ACI 318M-19 (ACI, 2019), assim como apresentada, respectivamente, nas Equação 2.2 e Equação 2.3.

$$V_c = 0,66\lambda_s\lambda(\rho_w)^{\frac{1}{3}}\sqrt{f'_c}b_wd \quad \text{Equação 2.2}$$

$$V_s = \frac{A_v f_{yt} (\sin \alpha + \cos \alpha) d}{s} \quad \text{Equação 2.3}$$

Onde

λ_s é o fator de efeito escala, adotado como $\lambda_s = \sqrt{\frac{2}{1+0,004d}} \leq 1$ na ausência de

armadura transversal, ou $\lambda_s = 1$ na presença de armadura transversal;

λ é um fator para contemplar concretos leves, sendo igual a 1 para concretos convencionais;

ρ_w é a taxa de armadura longitudinal em relação à alma da viga;

f'_c é a resistência à compressão do concreto;

b_w e d são, respectivamente, a largura da alma e a altura útil da seção transversal da viga;

A_v é a área de armadura transversal na alma;

f_{yt} é a tensão de escoamento das armaduras transversais, limitado à 420MPa;

s é o espaçamento da armadura transversal;

α é a orientação da armadura transversal em relação ao eixo do elemento.

A contribuição do FRP é determinada de forma semelhante as armaduras transversais internas, conforme a Equação 2.4.

$$V_f = \frac{A_{fv} f_{fe} (\sin \alpha + \cos \alpha) d_{fv}}{s_f} \quad \text{Equação 2.4}$$

Onde:

A_{fv} é a área de FRP que atravessa a fissura de cisalhamento principal;

f_{fe} é a tensão de tração efetiva no FRP;

d_{fv} é a distância entre a extremidade superior do FRP e as armaduras longitudinais;

α é a orientação das fibras em relação ao eixo do elemento;

s_f é a distância entre centros de dois reforços de FRP sucessivos.

Para tiras de FRP de seção retangular, a área dessa seção pode ser obtida conforme a Equação 2.5, considerando n camadas de FRP, com espessura de t_f e largura de w_f .

$$A_{fv} = 2nt_f w_f \quad \text{Equação 2.5}$$

A tensão efetiva que se desenvolve no FRP dependerá da configuração escolhida (reforço lateral, em “U” ou por envolvimento completo da seção), do comprimento efetivo aderido e da rigidez do reforço. Adotando um comportamento linear elástico, a tensão efetiva poderá ser estimada a partir do módulo de elasticidade à tração do FRP (E_f) e a deformação efetiva desenvolvida nele (ε_{fe}), conforme a Equação 2.6.

$$f_{fe} = E_f \varepsilon_{fe} \quad \text{Equação 2.6}$$

Para membros reforçados com envolvimento completo, a deformação efetiva pode ser estimada como o menor valor entre 0,004 e 75% da deformação de ruptura do FRP (ε_{fu}). Nos demais casos, esse parâmetro pode ser obtido pela Equação 2.7.

$$\varepsilon_{fe} = k_v \varepsilon_{fu} \leq 0,004 \quad \text{Equação 2.7}$$

Onde k_v é um coeficiente relativo à redução da aderência, dado por:

$$k_v = \frac{k_1 k_2 L_e}{11900 \varepsilon_{fu}} \leq 0,75 \quad \text{Equação 2.8}$$

Os fatores k_1 (Equação 2.9) e k_2 (Equação 2.10) consideram, respectivamente, a resistência do concreto e o tipo de envolvimento, enquanto o L_e (Equação 2.11) representa o comprimento de aderência ativado.

$$k_1 = \left(\frac{f'_c}{27} \right)^{\frac{2}{3}} \quad \text{Equação 2.9}$$

$$k_2 = \begin{cases} \frac{d_{fv} - L_e}{d_{fv}}, & \text{para reforço em "U"} \\ \frac{d_{fv} - 2L_e}{d_{fv}}, & \text{para reforço lateral} \end{cases} \quad \text{Equação 2.10}$$

$$L_e = \frac{23300}{(n t_f E_f)^{0,58}} \leq 0,75 \quad \text{Equação 2.11}$$

Onde f'_c é expresso em MPa e d_{fv} é a altura efetiva do FRP.

2.3.2 *Fib Bulletin 14*

A abordagem apresentada na fib Bulletin 14, (2001) também é baseada na analogia da treliça, porém, as deformações efetivas no FRP são obtidas por meio de expressões desenvolvidas a partir de resultados experimentais, onde é recomendado estimar as contribuições do concreto e da armadura transversal interna conforme os critérios da EUROCODE 2, (2004). Nessa normativa, a resistência total ao esforço cortante de um elemento reforçado é dada pela Equação 2.12.

$$V_{Rd} = \min \left\{ \begin{array}{l} V_{cd} + V_{wd} + V_{fd} \\ V_{Rd,2} \end{array} \right. \quad \text{Equação 2.12}$$

Onde:

V_{cd} é a parcela de resistência do concreto;

V_{wd} é a parcela de resistência da armadura transversal interna;

$V_{Rd,2}$ é o limite que representa a falha por esmagamento da biela comprimida.

Os parâmetros descritos devem ser obtidos segundo a EUROCODE 2 (2004). Para vigas sem estribos e apenas com armaduras de flexão, a contribuição do concreto à resistência ao cortante é dada pela Equação 2.13 e a contribuição dos estribos é estimada pela Equação 2.14.

$$V_{cd} = V_{Rd,c} = \frac{0,18}{\gamma_c} k (100 \rho_l f_{ck})^{1/3} b_w d \quad \text{Equação 2.13}$$

$$V_{wd} = V_{Rd,s} = \frac{A_{sw}}{s} z f_{ywd} \cot \theta \quad \text{Equação 2.14}$$

Onde:

d e b_w são a altura efetiva e a largura da alma da seção transversal de concreto armado;

f_{ck} é a resistência característica à compressão do concreto;

k é um fator para considerar a efeito escala, obtido por $k = 1 + \sqrt{\frac{200}{d}} \leq 2,0$, com

d em mm;

ρ_l é a taxa de armadura longitudinal, dada por $\rho_l = \frac{A_{s1}}{b_w d} \leq 0,02$;

A_{sw} é a área da seção transversal dos estribos;

s é o espaçamento entre estribos;

z é o braço de alavanca entre as resultantes de compressão e tração na seção transversal, estimada por $z = 0,9d$;

f_{ywd} é a resistência ao escoamento para o aço da armadura transversal.

A contribuição reforço de FRP à resistência ao cisalhamento pode ser obtida pela Equação 2.15.

$$V_{fd} = 0,9\varepsilon_{fd,e}E_{fu}\rho_f b_w d(\cot \theta + \cot \alpha) \sin \alpha \quad \text{Equação 2.15}$$

Onde:

$\varepsilon_{fd,e}$ é a deformação efetiva característica do FRP;

E_{fu} é o módulo de elasticidade do FRP no sentido das fibras;

ρ_f é a taxa de FRP, igual a $\rho_f = \frac{2t_f \sin \alpha}{b_w}$ para reforço contínuo e $\rho_f = \frac{2(t_f w_f)}{b_w s_f}$ para

o reforço discreto;

t_f é a espessura do FRP;

w_f é a largura de uma faixa de FRP (para o reforço discreto);

s_f é o espaçamento entre duas faixas sucessivas de FRP (para o reforço discreto);

α é a orientação das fibras;

θ é a inclinação da biela comprimida.

O valor da deformação efetiva característica do FRP é obtido a partir da Equação 2.16.

$$\varepsilon_{fd,e} = k \left(\frac{\varepsilon_{fk,e}}{\gamma_f} \right) \quad \text{Equação 2.16}$$

Onde $k = 0,8$, $\gamma_f = 1,30$ e a deformação específica característica, $\varepsilon_{fk,e}$, pode ser obtida conforme as Equação 2.17 a Equação 2.19, onde E_{fu} deve ser estar em GPa e f_{cm} em MPa.

a) Reforço com envolvimento completo (ou ancorado) com CFRP:

$$\varepsilon_{f,e} = 0,17 \left(\frac{f_{cm}^{\frac{2}{3}}}{E_{fu}\rho_f} \right)^{0,3} * \varepsilon_{fu}, \text{ com ruptura do FRP controlada} \quad \text{Equação 2.17}$$

b) Reforço em “U” ou lateral com CFRP:

$$\varepsilon_{f,e} = \min \begin{cases} 0,65 \left(\frac{f_{cm}^{\frac{2}{3}}}{E_{fu}\rho_f} \right)^{0,56} * 10^{-3}, \text{ com descolamento controlado} \\ 0,17 \left(\frac{f_{cm}^{\frac{2}{3}}}{E_{fu}\rho_f} \right)^{0,3} * \varepsilon_{fu}, \text{ com ruptura do FRP controlada} \end{cases} \quad \text{Equação 2.18}$$

- c) Reforço por envolvimento completo com AFRP (polímero reforçado com fibra de aramida):

$$\varepsilon_{f,e} = 0,048 \left(\frac{f_{cm}^{\frac{2}{3}}}{E_{fu}\rho_f} \right)^{0,47} * \varepsilon_{fu}, \text{ com ruptura do FRP controlada} \quad \text{Equação 2.19}$$

2.3.3 Fib Bulletin 90

A fib Bulletin 90 (Balázs *et al.*, 2019), além de apresentar a metodologia para estudo das contribuições do concreto, dos estribos e do FRP na resistência do elemento reforçado, é destacada a necessidade de considerar os efeitos de componentes resistentes ocasionadas por protensão ou membros com seção variável. Ademais, para membros que possuem estribos, a contribuição do concreto é desprezada. Dessa forma, a capacidade resistente total ao cisalhamento pode ser obtida conforme a Equação 2.20.

$$V_{Rd} = V_{Rd,s} + V_{Rd,f} + V_{ccd} + V_{td} \quad \text{Equação 2.20}$$

Onde:

V_{Rd} é o esforço cortante resistente total do elemento reforçado;

$V_{Rd,s}$ é a parcela do esforço cortante resistente atribuído aos estribos (conforme Equação 2.14);

$V_{Rd,f}$ é a parcela do esforço cortante resistente atribuída ao FRP;

V_{ccd} e V_{td} são as contribuições das componentes de cisalhamento nas áreas comprimidas e tracionadas para os casos de membros com seção variadas, respectivamente.

A parcela resistida pelo FRP pode ser estimada a partir da Equação 2.21.

$$V_{Rd,f} = \frac{A_{fw}}{s_f} h_f f_{fwd} (\cot \theta + \cot \alpha) \sin \alpha \quad \text{Equação 2.21}$$

Onde:

A_{fw} é a área de FRP em uma seção;

s_f é o espaçamento entre as faixas de FRP;

h_f é a altura do FRP que cruza a fissura principal de cisalhamento;

f_{fwd} é a tensão efetiva no FRP;

α é a orientação das fibras;

θ é a inclinação da biela comprimida.

Nos casos do reforço de FRP com envolvimento completo, a tensão efetiva desenvolvida é calculada pela Equação 2.22.

$$f_{fwd} = f_{fwd,c} = k_R a_t f_{fd} \quad \text{Equação 2.22}$$

Onde:

a_t é tomado como 0,8;

k_R é calculado em função do raio (R), em milímetros, das arestas da seção que é envolvida pelo reforço de FRP, conforme a Equação 2.23.

$$k_R = \begin{cases} \frac{0,5R}{50} \left(2 - \frac{R}{50} \right), & \text{se } R < 50mm \\ 0,5, & \text{se } R \geq 50mm \end{cases} \quad \text{Equação 2.23}$$

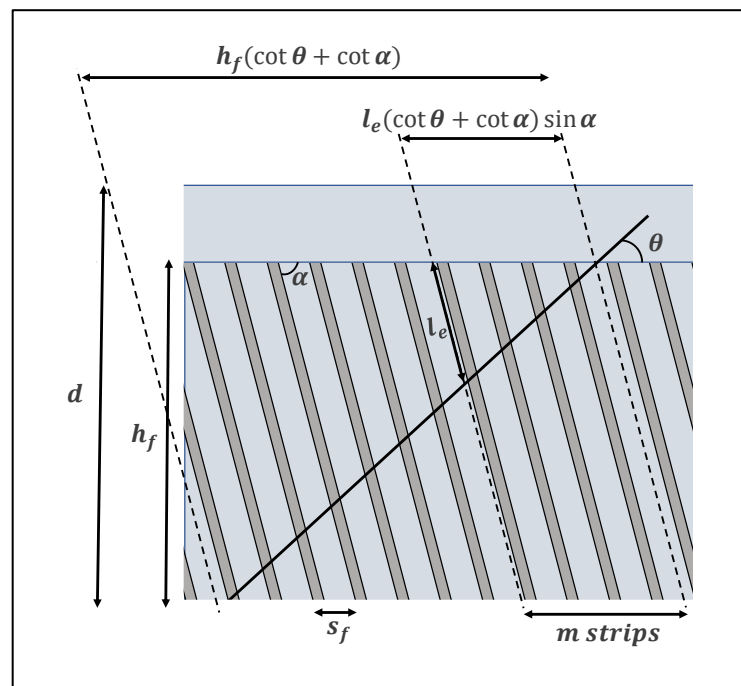
No caso do reforço em forma de “U”, a tensão efetiva pode estar associada à ocorrência da ruptura do reforço (obtida pela Equação 2.22) ou ao descolamento do FRP

(f_{fbwd}), sendo recomendado, para fins de projeto, adotar o menor valor entre eles. No caso de descolamento do FRP, devem ser consideradas três situações:

- Todas as faixas do reforço acima da fissura crítica de cisalhamento estão completamente ancoradas;
- Apenas algumas estão ancoradas;
- Nenhuma está ancorada.

A Equação 2.24, desenvolvida considerando o esquema apresentado na Figura 3, contempla as situações de ancoragem comentadas anteriormente da tensão efetiva a ser considerada na análise.

Figura 3 - Referência para o desenvolvimento da Equação 2.24 para determinação da tensão efetiva no caso do descolamento do FRP.



Fonte: Adaptado de Balázs et al., (2019).

f_{fbwd}

$$= \frac{f_{fbk}}{\gamma_{fb}} \begin{cases} 1, \text{ se } l_e \leq \frac{s_f}{(\cot \theta + \cot \alpha) \sin \alpha} \leq \frac{h_f}{\sin \alpha} \\ \left[1 - \left(1 - \frac{2ms_f}{3l_e} \right) \frac{m}{n} \right], \text{ se } \frac{s_f}{(\cot \theta + \cot \alpha) \sin \alpha} \leq l_e \leq \frac{h_f}{\sin \alpha} \\ \frac{2n}{3l_e} \frac{s_f}{(\cot \theta + \cot \alpha) \sin \alpha}, \text{ se } \frac{s_f}{(\cot \theta + \cot \alpha) \sin \alpha} \leq \frac{h_f}{\sin \alpha} \leq l_e \end{cases}$$

Equação 2.24

Onde:

γ_{fb} é o coeficiente de segurança geralmente utilizado em análises que envolvem aderência e é tomado igual a 1,5;

l_e é o comprimento mínimo de ancoragem necessário para desenvolver as tensões de ruptura do FRP;

m é a quantidade de faixas de FRP que tem comprimento de ancoragem menor que l_e ;

n é a quantidade de faixas que interceptam a fissura crítica;

h_f é a altura útil do reforço, que pode ser aproximado por $h - 0,1d$.

Na Equação 2.24, f_{fbk} é a tensão de aderência máxima do reforço, dada pela Equação 2.25.

$$f_{fbk} = \sqrt{\frac{E_f t_f s_{0k}}{\tau_{b1k}}} \quad \text{Equação 2.25}$$

Onde:

E_f é o módulo de elasticidade do reforço;

t_f é a espessura do reforço;

s_{0k} é o deslizamento característico último para o CFRP, que pode ser tomado como 0,20mm;

τ_{b1k} é a tensão de cisalhamento devido ao atrito por aderência, calculada com a Equação 2.26, em que f_{cm} e f_{ctm} são, respectivamente, a resistência à compressão e à tração média do concreto, comumente o elo mais fraco do sistema de reforço.

$$\tau_{b1k} = 0,37\sqrt{f_{cm}f_{ctm}} \quad \text{Equação 2.26}$$

A quantidade de faixas de FRP que atravessa a fissura crítica pode ser estimada pelas Equação 2.27 e Equação 2.28, e o comprimento de ancoragem efetivo mínimo (l_e) pode ser calculado pela Equação 2.29.

$$n = \text{inteiro} \left(\frac{h_f (\cot \theta + \cot \alpha)}{s_f} \right) \quad \text{Equação 2.27}$$

$$m = \text{inteiro} \left(\frac{l_e (\cot \theta + \cot \alpha) \sin \alpha}{s_f} \right) \quad \text{Equação 2.28}$$

$$l_e = \frac{\pi}{2} \sqrt{\frac{E_f t_f S_{0k}}{\tau_{b1k}}} \quad \text{Equação 2.29}$$

Em algumas situações, a tensão efetiva para o caso de envolvimento completo pode apresentar valores inferiores aos obtidos para casos em que espera-se a ocorrência de descolamento. Tal comportamento está relacionado ao fator k_R (Equação 2.23), fato mencionado no estudo de Kotynia, (2011), que foi incorporado para considerar a possibilidade de falha por concentrações de tensões que podem ocorrer nas regiões de mudança de direção do reforço.

2.4 Regressão Linear Múltipla

A regressão múltipla consiste em elaborar um modelo probabilístico que relacione uma variável dependente y a mais de uma variável independente. Seja k o número de variáveis preditoras, com $k \geq 2$, e o conjunto de preditores x_1, x_2, \dots, x_k . A equação geral para o modelo de regressão linear múltipla é dada por:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon$$

O termo ϵ é uma variável aleatória chamada de desvio aleatório ou erro aleatório do modelo. A presença desse termo permite a inclusão de dados que estão dispersos próximos à reta de regressão, seja acima ($\epsilon > 0$) ou abaixo ($\epsilon < 0$). Os termos $\beta_0 + \beta_1 x_1$, para quando $k = 2$, descrevem uma função de x correspondente a uma regressão linear simples, enquanto a função $\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$, também chamada de função de regressão real, descreve o valor de y em função dos preditores x_1, x_2, \dots, x_k . Os coeficientes de regressão reais β_i podem ser interpretados como a mudança esperada em y associada ao aumento de uma unidade em x_i , quando os demais coeficientes são mantidos fixos.

2.5 Inteligência Artificial

A Inteligência artificial (IA) é uma área da ciência da computação que estuda como as máquinas podem ser concebidas para agir de forma inteligente, envolvendo habilidades psicológicas, como percepção, associação, previsão e planejamento, bem como diversas capacidades de processamento de informações (Wang, Yifeng; Wang; Zhang, 2024). O conceito é amplo e apresenta diversas definições quando analisados sob diferentes perspectivas.

Os primeiros estudos acerca da IA surgiram a partir da década de 1940, tendo como uma de suas motivações a Segunda Guerra Mundial. Neste período, houve a necessidade de desenvolver uma tecnologia voltada para a análise de balística, quebra de códigos e cálculos para projetos de armas nucleares, assim, originando os primeiros grandes projetos de construção de computadores. Após a Segunda Guerra Mundial, o computador não ficou restrito aos âmbitos militar e científico, sendo gradualmente utilizado em outros setores da sociedade (Lopes; Santos; Pinheiro, 2014).

Em seus estudos, Mai *et al.*, (2024) discutiram algumas das aplicações da inteligência artificial na área da engenharia civil, com destaque aos âmbitos da segurança, comunicação e manutenção do setor da construção. Dentre as potencialidades do uso da IA nos serviços de engenharia, os autores destacam melhorias nas fases de planejamento e projeto (Darko *et al.*, 2020; Regona *et al.*, 2022; Smith; Wong, 2022); robótica e automação na construção (Gharbia *et al.*, 2020; Pan; Zhang, 2021); e controle de qualidade e construções sustentáveis (Di Vaio *et al.*, 2020; Kardovskyi; Moon, 2021; Manzoor *et al.*, 2021).

2.5.1 *Aprendizado de máquina*

O aprendizado de máquina (AM), como um subcampo de estudo da IA, investiga algoritmos e modelos estatísticos que os sistemas de computador utilizam para executar uma tarefa específica, como processos de classificação, regressão e agrupamento, sem serem explicitamente programados (Wang, Yifeng; Wang; Zhang, 2024). Com comportamento semelhante ao cérebro humano, os modelos de AM adquirem o conhecimento para completar a meta analisando uma grande quantidade de dados. Conforme diferentes mecanismos de treinamento, o aprendizado de máquina pode ser dividido em aprendizado por reforço, aprendizado supervisionado, aprendizado semi-supervisionado e aprendizado não supervisionado (WANG, SHIQI *et al.*, 2023). As definições desses conceitos serão discutidas com base em Russell; Norvig, (2013).

No aprendizado por reforço, o agente aprende a partir de uma série de reforços, podendo ser recompensas ou punições, cujo objetivo principal é fazer com que ele aprenda a tomar decisões de forma a maximizar as recompensas ao longo do tempo, sendo amplamente utilizado na robótica. No aprendizado supervisionado, por sua vez, o agente conhece as entradas e saídas e, iterativamente, vai ajustando a sua tomada de decisão até que o erro envolvido entre os resultados gerados e aqueles inseridos esteja em um limite aceitável definido inicialmente.

No aprendizado não supervisionado, os agentes exploram dados não rotulados para que sejam identificados padrões nesse conjunto. A tarefa mais comum nesse tipo de aprendizado é o agrupamento e categorização, isto é, a definição de grupos potencialmente úteis. Por fim, no aprendizado semi-supervisionado, são fornecidos ao agente uma série de dados com pontos rotulados (isto é, possuindo entradas e saídas bem definidas) e pontos não rotulados (com apenas uma informação fornecida). Esse modelo reúne características de um modelo supervisionado (para a análise dos dados rotulados) e não supervisionado (para a análise dos dados não rotulados).

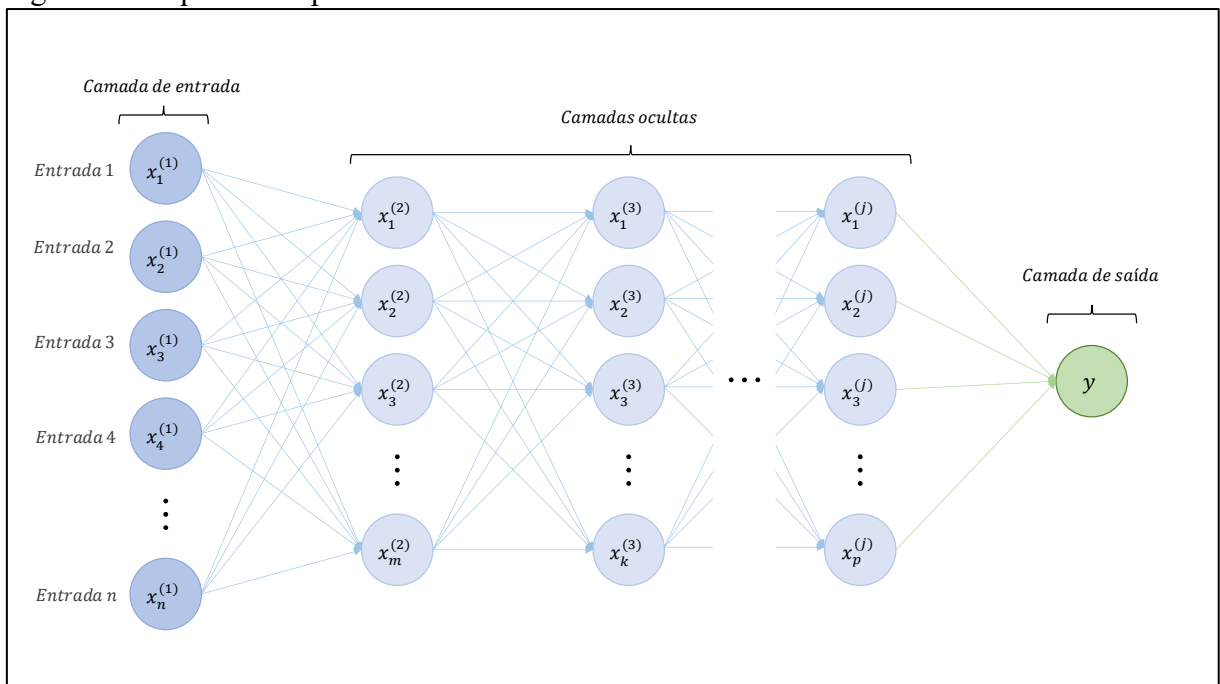
O emprego de técnicas de aprendizado de máquina na modelagem de sistemas estruturais tem ganhado destaque devido ao seu potencial em mapear relações complexas entre parâmetros de interesse sem a necessidade de predefinir modelos matemáticos ou físicos previamente (Wakjira; Ebead; Alam, 2022). Dentre as diversas aplicações dessas abordagens na engenharia civil, destacam-se: a avaliação de integridade e danos em pontes e edifícios (Fathalla; Tanaka; Maekawa, 2018; Mangalathu *et al.*, 2019; Morfidis; Kostinakis, 2018; Weinstein *et al.*, 2018; Yan *et al.*, 2019); a caracterização de propriedades fundamentais dos materiais (Ben Chaabene; Flah; Nehdi, 2020; Feng, De Cheng *et al.*, 2020; Yu *et al.*, 2018); a predição da capacidade de carga e dos modos de falha em elementos de concreto armado (Feng, De-Cheng *et al.*, 2021; Fu; Feng, 2021; Mangalathu; Jeon, 2018, 2019; Reza; Alam; Tesfamariam, 2014); e a análise do desempenho sísmico de estruturas (Calofir *et al.*, 2025; De Iuliis; Miceli; Castaldo, 2024; Tang *et al.*, 2025; Zhou, Ying; Huang; Lu, 2026) .

2.5.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA), também conhecidas como neurocomputadores, tratam-se de um modelo computacional que imita o funcionamento do cérebro humano que consegue processar entradas e mapeá-las iterativamente em um número arbitrário de matrizes até que o processo resulte em um modelo com o menor erro possível e

uma aproximação de uma solução (Abuodeh; Abdalla; Hawileh, 2020). A partir de uma série de neurônios conectados, cada um deles analisa as saídas dos outros neurônios ligados a ele, realiza cálculos e, em seguida, retorna se o valor calculado está dentro do limite definido ou não (a arquitetura típica de uma RNA é apresentada na Figura 4). As RNA são utilizadas para resolver uma ampla variedade de problemas, como reconhecimento de caracteres manuscritos e detecção facial, além de suas potencialidades no aprendizado profundo (GRUS, 2021).

Figura 4 - Arquitetura típica de uma rede neural artificial.



Fonte: Elaborado pelo autor.

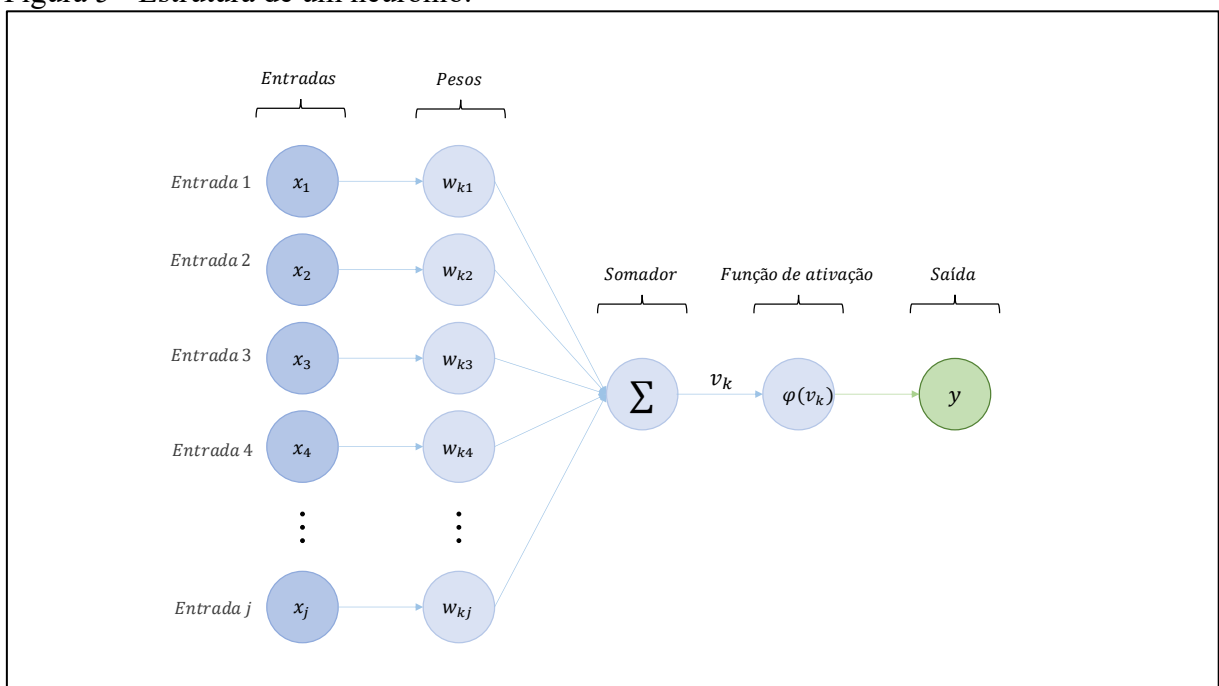
Segundo Haykin, (2001), considerando as RNA como um processador constituído de unidades de processamento simples, elas se assemelham ao cérebro humano em dois aspectos principais: primeiro, o conhecimento é obtido pela rede a partir de um processo de aprendizagem em seu ambiente; e, segundo, as forças de conexão entre os neurônios, ou pesos sinápticos, são empregados para armazenar o conhecimento adquirido a cada iteração. Nessa perspectiva, o procedimento que fundamenta uma RNA consiste em modificar os pesos sinápticos de forma ordenada para que seja alcançado o objetivo para o qual ela foi criada.

Um neurônio, unidade básica de uma rede neural, é formado basicamente por três elementos básicos: um conjunto de sinapses, um somador e uma função de ativação (Figura 5). As sinapses são caracterizadas por pesos, em que um sinal de entrada da sinapse x_j conectada ao neurônio k é multiplicado por um peso w_{kj} , onde o primeiro índice indica o neurônio em

questão e o segundo se refere ao terminal sináptico de entrada à qual o peso corresponde. Posteriormente, um somador aplica uma combinação linear, consistindo na soma dos sinais de entrada ponderados pelas respectivas sinapses do neurônio.

Por fim, uma função de ativação ($\varphi(x)$), também chamada de função restritiva, é empregada para restringir a amplitude da saída de um neurônio, assim, limitando o intervalo do sinal de saída a um valor finito. Frequentemente, o intervalo normalizado é escrito como um intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

Figura 5 - Estrutura de um neurônio.



Fonte: Elaborado pelo autor.

Conforme apresentado por Haykin, (2001), a função de ativação define a saída de um neurônio, podendo ser de três tipos básicos: função de limiar (a saída do neurônio assume o valor 1, se o campo induzido local (v_k) é não-negativo e 0 caso contrário); função linear por partes (uma aproximação de um amplificador não-linear); e a função sigmóide (mais utilizada na construção de RNA). A Tabela 2 apresenta a definição matemática dessas funções.

Tabela 2 - Funções de ativação básicas.

Função de ativação	Equação
Função limiar	$\varphi(v_k) = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases}$
Função linear por partes	$\varphi(v_k) = \begin{cases} 0 & \text{se } v_k \leq -\frac{1}{2} \\ v_k & \text{se } -\frac{1}{2} < v_k < \frac{1}{2} \\ 1 & \text{se } v_k \geq \frac{1}{2} \end{cases}$
Função sigmóide	$\varphi(v_k) = \frac{1}{1 + e^{-av_k}}$

Fonte: Haykin, (2001)

2.5.3 Técnicas de regularização

Um modelo de redes neurais simples pode ser compreendido como um modelo onde a distribuição dos valores dos seus parâmetros tem menor entropia ou com menos parâmetros. A regularização de pesos é uma forma de mitigar o *overfitting* por meio da imposição de restrições na complexidade de uma rede, forçando seus pesos a assumirem apenas valores pequenos, o que torna a distribuição dos valores dos pesos mais regular. Tal processo é feito adicionando à função de perda da rede um custo associado a ter pesos grandes. (Chollet; Watson, 2025)

Dentre as técnicas de regularização, destacam-se a regularização L1 (que atua na equação matemática) e o *Dropout* (que atua na arquitetura da rede). A Regularização L1 - também conhecida como LASSO, do inglês *Least Absolute Shrinkage and Selection Operator* - aprimora o modelo adicionando a penalidades ao custo computacional em função da soma dos valores absolutos dos coeficientes de peso dos neurônios da camada, promovendo a esparsidade e a seleção das características mais relevantes.

Na regularização L1, a penalidade pode ser equivalente ao valor absoluto das magnitudes dos coeficientes, o que reduz alguns coeficientes a zero, removendo as características irrelevantes em um conjunto de dados. Isso incentiva a esparsidade no modelo e torna a regularização L1 muito útil para a seleção de características em modelos com muitas variáveis. O termo de penalidade adicionado pela regularização L1 é a soma dos valores absolutos dos coeficientes, multiplicada por um parâmetro de regularização (λ).

$$Total\ loss = [Loss\ function] + \left[\lambda \sum |w_i| \right] \quad \text{Equação 2.30}$$

Performance Termo da penalidade L1

Na Equação 2.30, w_i representa os coeficientes do modelo e λ é um hiperparâmetro não negativo que controla a intensidade da penalização. Quanto maior o valor de λ , mais significativa é a penalização e, portanto, mais coeficientes podem ser reduzidos a zero. Como a regularização L1 pode reduzir coeficientes a zero, ela efetivamente remove algumas características do modelo. Esta técnica de regularização se torna particularmente útil ao lidar com dados de alta dimensionalidade, onde algumas características podem ser irrelevantes ou redundantes. Dessa forma, são selecionadas as características mais importantes.

O *Dropout*, por sua vez, é uma técnica, desenvolvida por Geoff Hinton e sua equipe, na Universidade de Toronto, que consiste em desativar aleatoriamente um número de características de saída da camada durante o treinamento. Na prática, consiste em associar a determinados neurônios uma saída nula para uma determinada amostra de entrada durante o treinamento. A taxa de *dropout* é a fração das características que são zeradas; geralmente é definida entre 20% e 50%.

2.5.4 Verificação de desempenho

A verificação do modelo desenvolvido em RNA pode ser feita de diversas formas. Oliveira *et al.*, (2024), em seus estudos, adotaram como métrica a utilização do erro absoluto médio (MAE, do inglês *Mean Absolute Error*), a raiz do erro quadrático médio (RMSE, do inglês *Root Mean Squared Error*), o erro quadrático médio (MSE, do inglês *Mean Squared Error*) e o coeficiente de determinação (R^2). As formulações adotadas para cada um desses parâmetros são apresentadas na Tabela 3. Na interpretação desses erros, é importante fazer as seguintes considerações:

- a) O MAE não é sensível a *outliers*, em que, quanto menor, melhor é a precisão do modelo;
- b) O MSE é uma medida mais sensível a *outliers*, visto que evidencia erros maiores;
- c) O RMSE é a raiz quadrada do MSE, sendo expresso na mesma unidade de grandeza observada;

- d) O R^2 representa a adequação do modelo aos dados observados, em que valores próximos de 1 podem indicar melhores ajustes.

Tabela 3 - Métricas para verificação do desempenho do modelo de RNA.

Métrica de verificação	Equação
Erro absoluto médio	$MAE = \frac{\sum_{i=1}^n \hat{y}_i - y_i }{n}$
Raiz do erro quadrático médio	$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$
Erro quadrático médio	$MSE = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}$
Coefficiente de determinação	$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$

Onde:

\hat{y}_i é o valor estimado pelo modelo;

y_i é o valor real observado;

\bar{y} é a média dos dados reais observados;

n é a quantidade de observações.

Fonte: (Oliveira *et al.* 2024)

3 ESTADO DA ARTE

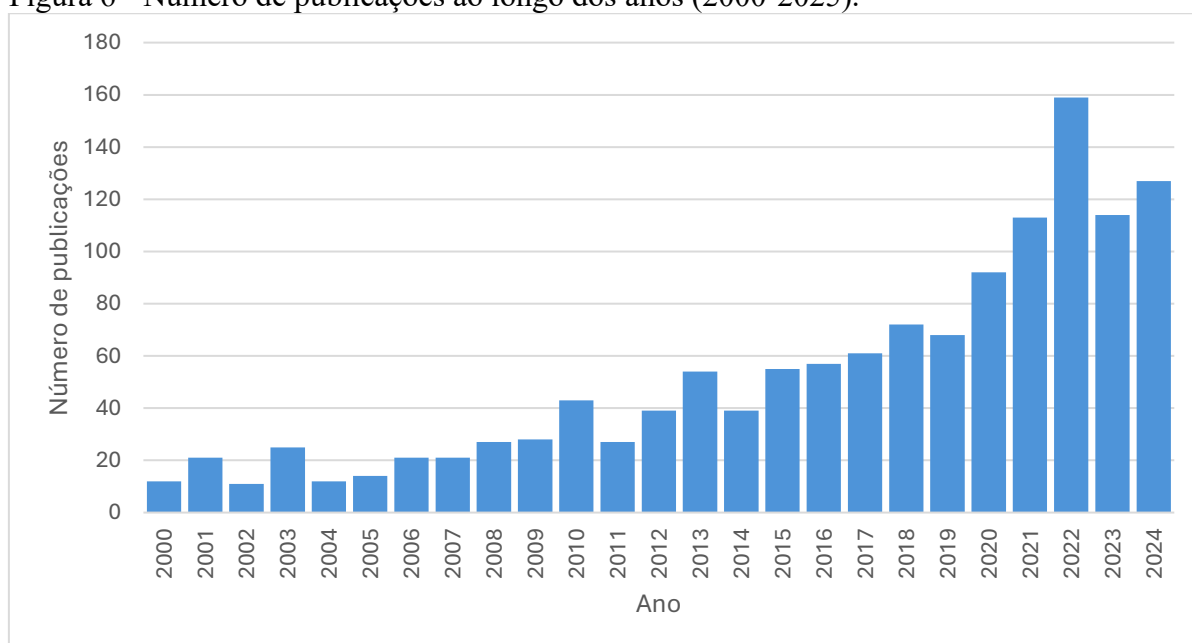
O reforço ao cisalhamento de vigas de concreto armado com FRP tem despertado interesse de pesquisadores devido suas potencialidades nos serviços de reforço estrutural. Conforme uma pesquisa realizada na base de dados *Web of Science*, segundo os critérios de busca apresentados na Tabela 4, o número de publicações sobre esse tópico (Figura 6), incluindo documentos como artigos de pesquisa e revisão, relatórios técnicos e capítulos de livro, tem crescido gradativamente, considerando o período de 2000-2024, sobretudo a partir de 2009. Dentre os motivos desse crescimento no número de publicações pode-se citar a popularização desse tipo de reforço estrutural, também motivado por características como sua alta resistência mecânica e baixo peso, rápida execução e resistência química.

Tabela 4 - Critérios de busca na base de dados.

Palavras chaves	Beam; shear reinforcement; FRP; reinforced concrete
Data de acesso	18 de fevereiro de 2025
Período de publicação	2000 – 2024
Área temática	Engineering
Artigos encontrados	1316 publicações

Fonte: Elaborado pelo autor.

Figura 6 - Número de publicações ao longo dos anos (2000-2025).



Fonte: Elaborado pelo autor.

No período analisado, foram encontrados um total de 1316 trabalhos na base de dados (ver Tabela 5). Desses trabalhos, 395 publicações tratam do estudo de modelos de prescrição da resistência ao cisalhamento, seja desenvolvimento de novas metodologias ou análise de abordagens existentes. Além disso, uma parcela de 34 publicações aborda a aplicação de ferramentas de IA e *machine learning* nos modelos de predição de resistência, demonstrando ser uma linha de pesquisa pouco explorado por pesquisadores.

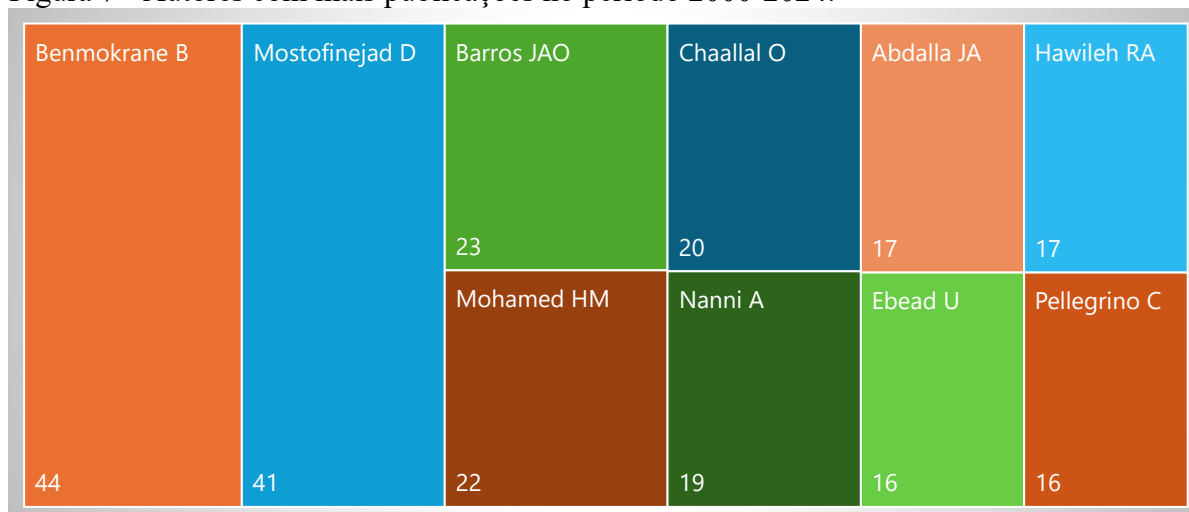
Tabela 5 - Critérios de busca na base de dados para diferentes áreas de estudo.

Assunto	Palavras chaves	Número de publicações
Reforço ao cisalhamento de vigas de concreto armado	Beam; shear reinforcement; FRP; reinforced concrete	1316
Modelos de prescrição da resistência ao cisalhamento	Beam; shear reinforcement; FRP; reinforced concrete; predicting	395
Aplicação de ferramentas de IA e <i>machine learning</i> para prescrição da resistência ao cisalhamento	Beam; shear reinforcement; FRP; reinforced concrete; predicting; artificial intelligence; machine learning	34

Fonte: Elaborado pelo autor.

A Figura 7 apresenta os 10 autores com mais publicações no período de 2000-2024, com destaque para Benmokrane B. (Canadá), Mostofinejad D. (Irã) e Barros JOA (Portugal), respectivamente, com 44, 41 e 23 publicações. Além disso, as nacionalidades desses autores, juntamente com pessoas da China, são os países com mais pesquisas na área de reforço estrutural com FRP.

Figura 7 - Autores com mais publicações no período 2000-2024.



Fonte: Elaborado pelo autor.

Nos tópicos seguintes dessa seção serão apresentados alguns dos trabalhos publicados nos últimos anos que se propuseram a estudar o reforço ao cisalhamento de vigas de concreto armado com FRP, modelos de prescrição de resistência e a aplicação de ferramentas de IA e aprendizado de máquina para predição da resistência ao cisalhamento dos elementos reforçados. O objetivo deste estado da arte é oferecer uma visão geral dos principais aspectos dessa temática que vêm sendo explorados recentemente.

3.1 Reforço ao cisalhamento de vigas de concreto armado com FRP

O uso laminados de BFRP (polímero reforçado com fibras de basalto) para aumentar a resistência ao cisalhamento e restaurar a integridade estrutural de vigas contínuas de concreto armado de alta resistência foi investigado por Abdel-Jaber *et al.*, (2026). Os autores combinaram um estudo experimental com simulações numéricas com o objetivo de compreender as aplicações do BFRP como reforço estrutural e assistir o desenvolvimento de procedimentos de reforço estrutural eficientes e duráveis. Foi observado que a utilização desse material como alternativa de reforço promoveu ganhos de resistência ao cisalhamento que variaram de 17% a 37,4%. No caso de vigas previamente danificadas, a melhoria foi moderada, variando entre 5,7% e 19,4%. Além disso, os resultados experimentais foram consistentes com os resultados obtidos por meio de análise numérica, de forma que o método computacional apresentado reproduziu com precisão o comportamento estrutural observado durante os ensaios.

Waqas; Elahi; Kırgız, (2025) também utilizaram uma abordagem híbrida de ensaios experimentais e simulações numéricas para avaliar a eficácia do CFRP (polímero reforçado com fibra de carbono) no reforço de vigas de concreto armado com deficiência de resistência ao cisalhamento. Para isso, vigas de concreto armado com diferentes níveis de dano foram reforçadas ao cisalhamento, com diferentes alturas e larguras, e todos os corpos de prova foram reforçados com CFRP em forma de U colado externamente. Os autores constataram que o reforço estrutural promoveu uma recuperação de até 90% da resistência e aumento significativo da ductilidade dos espécimes. Além disso, a curva carga-deflexão e o padrão de fissuração modelados via elementos finitos apresentaram um bom ajuste com os resultados experimentais.

O impacto do reforço ao cisalhamento em vigas de concreto armado utilizando fibras naturais e resinas epóxi locais foi investigado por Makhoulouf *et al.*, (2024). Segundo os autores, a utilização do reforço com FRP aumentou a resistência ao cisalhamento de 28% até 175%, a depender da configuração do reforço adotada. Além disso, foi utilizada uma

modelagem numérica que mostrou resultados concordantes com aqueles observados experimentalmente. O comportamento também foi observado por Akkaya; Aydemir; Arslan, (2024) ao estudarem vigas com baixa relação vão e altura efetiva, verificando que o uso de FRP melhorou as capacidades de cisalhamento e ductibilidade, bem como uma correlação com as taxas de armadura de cisalhamento vertical e horizontal inversa e direta, respectivamente.

A durabilidade das juntas de FRP e interface de concreto foi investigada por Hao *et al.*, (2024) por meio de exposição acelerada em laboratório e em campo, avaliando os elementos reforçados em diferentes períodos nos ambientes de ciclagem úmido-seco e externo. Os autores observaram que, a depender do material, as fibras têm diferentes níveis de degradação com o tempo, sobretudo no ambiente de ciclagem úmido-seco. Além disso, foram verificadas resistências à tração e compressão do concreto ligeiramente maiores, em razão do período pós-cura; e uma redução na resistência interfacial FRP-concreto, com alteração do modo de falha.

O descolamento da FRP da interface de concreto foi estudado, também, por Kong *et al.*, (2023), em que utilizaram, em conjunto, um método de percussão com aprendizagem profunda para identificar os danos presentes nas juntas FRP-concreto. Os autores observaram um potencial na aplicação de modelagem em elementos finitos, utilizando sinais de percussão, para a identificação desses danos. Por outro lado, Zhou *et al.*, (2023) investigaram o uso de dispositivos para reduzir o desenvolvimento de fissuras em vigas pré-fissuradas, onde verificaram que a capacidade resistente das vigas e sua ductibilidade aumentaram significativamente, bem como o limite inferior da carga nos corpos de prova superior aos valores obtidos a partir de formulações existentes.

Mamdouh *et al.*, (2024) analisaram o comportamento sob exposição ao fogo de vigas reforçadas com FRP com fibra de vidro. O programa experimental consistiu em doze vigas ensaiadas variando a taxa de reforço e o tempo de exposição ao fogo. Os autores pontuaram que maiores taxas de armadura longitudinal e de reforço promoveram, respectivamente, uma maior resistência ao cisalhamento; e uma redução na largura das fissuras e deflexões, onde este último é diretamente proporcional ao tempo de exposição ao fogo. Além disso, considerando uma mesma taxa de reforço, a capacidade resistente da viga é reduzida com o aumento do tempo exposto a altas temperaturas.

Yumnam *et al.*, (2021) analisaram a literatura para identificar modos comuns de defeitos em estruturas reforçadas e avaliar a aplicação de ensaios não destrutivos (END) para a avaliação desses elementos. Os autores mostraram que os defeitos podem surgir logo na execução do reforço, como defeitos de fabricação, resinas de baixa qualidade e quebra das

fibras, preparação inadequada dos materiais e do substrato, levando a delaminação e descolamento do FRP. Além disso, destacaram a propagação de fissuras, a quebra da resina, e o rompimento das fibras. Quanto aos END, observaram que muitas técnicas apresentam limitações quando aplicadas ao reforço de FRP, sendo o ensaio de termografia o mais indicado devido a facilidade de execução e sua natureza direta na identificação de danos superficiais.

Os estudos existentes na literatura investigam amplamente as diversas aplicações do reforço ao cisalhamento com FRP, analisando seu desempenho em diferentes condições de projeto. No entanto, observa-se que há tópicos nessa área que permanecem pouco explorados na literatura, como abordagens para prescrição da resistência ao cisalhamento e suas contribuições, aplicação de disciplinas como inteligência artificial e END, cargas cíclicas, explosões e grandes variações de temperatura.

3.2 Modelos de prescrição da resistência ao cisalhamento

Atualmente, algumas das diretrizes existentes, como ACI 440.2R-17 (ACI, 2017) e fib 14 (FIB BULLETIN 14, 2001), consideram a contribuição do reforço de FRP na resistência ao cisalhamento do elemento não reforçado. Porém, conforme apresentado por Oller; Kotynia; Mari, (2021), tais formulações são semelhantes à contribuição do reforço transversal interno para a resistência ao cisalhamento, baseada na analogia da treliça, com a diferença de que o reforço de FRP não escoa.

Em vista das evidências acerca do ganho de resistência com o uso de FRP, a previsão da resistência ao cisalhamento de vigas reforçadas começou a ser estudada por autores como Mohammadi; Barros; Sena-Cruz, (2024), a partir de evidências observadas em banco de dados experimentais. No estudo de Mohammadi; Barros; Sena-Cruz, (2024), por exemplo, foi constatado que o modelo proposto apresentou um potencial preditivo maior que os modelos de previsão considerados na pesquisa, com resultados mais confiáveis, econômicos e com menos incertezas e valores tendenciosos.

Dinh; Roh; Truong, (2024) se propuseram a melhorar o modelo teórico de Choi; Kim; Park, (2016) para aplicá-lo na previsão da resistência ao cisalhamento de vigas de concreto armado reforçadas por barras de FRP sem estribos, considerando as contribuições de resistência ao cisalhamento pela zona de compressão de concreto intacta e mecanismo de intertravamento de agregados. Os autores obtiverem um alto grau de precisão na previsão da

resistência ao cisalhamento, com o valor médio da razão de resistência ao cisalhamento de 1,02, e previu razoavelmente a deformação efetiva desenvolvida nas barras de flexão de FRP.

Yang *et al.* (2024) propuseram aprimorar um método de predição da resistência ao cisalhamento de vigas reforçadas com mantas de FRP de carbono, originalmente descrito por Loov (2011), introduzindo uma relação para a análise de interação parcial que considera tanto as tiras transversais de FRP quanto os reforços longitudinais. Os resultados indicaram que o modelo modificado apresentou previsões consistentes em comparação com os dados experimentais. Entretanto, em relação a outros modelos de predição aos quais foi comparado, mostrou-se mais conservador.

Pesquisas acerca da interação entre as armaduras de cisalhamento interna e externa e o desenvolvimento de modelos de previsão para a resistência ao cisalhamento de vigas de CA reforçadas com FRP foram realizadas por Chen; Teng; Chen, (2013a), que, em seus estudos acerca da interação das armaduras de cisalhamento interna e externa em vigas de CA reforçadas, nas configurações U e lateralmente, verificaram uma melhora nos resultados do seu modelo de resistência ao cisalhamento com a consideração de um fator de interação, quando comparado a outros modelos.

Ali *et al.*, (2021) estudaram o projeto de reforço ao cisalhamento de vigas de concreto armado com FRP sem estribos, avaliando diferentes metodologias para calcular a resistência ao cortante e comparando-os com um modelo de prescrição proposto a partir de observações experimentais e regressões multivariáveis não lineares. Os autores observaram que, dentre os modelos analisados, o padrão descrito pela CSA Group, (2012) produziu previsões mais precisas, embora conservadores. Além disso, o método proposto pelos autores, para as vigas de concreto armado reforçadas com FRP e sem estribos, apresentou uma correlação significativamente maior entre os valores de resistência experimental e previsto do que os métodos existentes na literatura.

Mohammadi, Amirhossein; Barros; Sena-Cruz, (2024) se propuseram a desenvolver um modelo de projeto abrangente para prever a resistência ao cisalhamento de vigas reforçadas com EB-FRP nas configurações em U e envolvimento completo da seção, realizando análises de acurácia e sensibilidade e validando o modelo com resultados experimentais obtidos. Os autores verificaram que o modelo desenvolvido apresentou um desempenho superior aos demais métodos analisados, com incertezas próximas a uma unidade. Além disso, a incorporação de parâmetros como o tipo de seção transversal, a armadura

transversal equivalente e a armadura longitudinal aumentaram sua capacidade de gerar previsões menos tendenciosas e mais consistentes.

Van Hong Bui, (2025) se propôs a desenvolver um método de predição da resistência ao cisalhamento com base na mecânica e considerando a interação complexa das tensões de cisalhamento, compressão e flexão, tendo como referência a abordagem apresentada por Choi *et al.*, (2014). Com esse estudo, o autor obteve resultados mais precisos do que as normativas analisadas, adequando-se à análise de vigas com seções retangulares e T. Ademais, o modelo desenvolvido revelou que a largura da mesa das vigas T é diretamente proporcional a capacidade resistente, assim, sendo recomendadas dimensões maiores para fins de projeto.

De modo geral, observa-se que não há um consenso na comunidade científica sobre uma abordagem que permita prever com precisão a resistência ao cisalhamento de vigas reforçadas com FRP. Embora existam diversos modelos de prescrição disponíveis na literatura adotando metodologias distintas para diferentes cenários de projeto, considerando variáveis como o formato da seção e a presença de estribos, ainda observam-se desafios quanto ao desenvolvimento de uma abordagem com capacidade de generalização e precisão aceitáveis.

3.3 Aplicação de ferramentas de IA e *machine learning* para prescrição da resistência ao cisalhamento

Nos últimos anos, o aprendizado de máquina tem sido empregado para a resolução de problemas complexos em razão da sua capacidade de analisar e estabelecer relações entre diversos parâmetros em um banco de dados. No estudo do reforço com polímeros reforçados com fibra, essa ferramenta tem sido utilizada para prever a resistência final ao cisalhamento do elemento reforçado, bem como a contribuição do FRP. Dentre os métodos utilizados, tem-se a utilização de Redes Neurais Artificiais (RNA), que se trata de um modelo computacional que imita o funcionamento do cérebro humano e consegue processar entradas e mapeá-las iterativamente em um número arbitrário de matrizes até que o processo resulte em um modelo com o menor erro possível e uma aproximação de uma solução (Abuodeh *et al.* 2020). Embora seja uma ferramenta promissora, a principal desvantagem das RNA é a sua natureza de caixa-preta, isto é, há pouca percepção da forma como os dados de entrada são analisadas para a obtenção da resposta final.

Mohammadi; Barros; Sena-Cruz, (2025) buscaram propor um modelo com desempenho preditivo superior aos modelos normativos e que corrigisse suas limitações. Para

isso, a estratégia adotada por eles consistiu numa abordagem híbrida, combinando métodos baseados em física e aprendizado de máquina, para, inicialmente, prever a deformação efetiva e, em seguida, utilizá-la para prever a contribuição na resistência ao cisalhamento do reforço. Dentre os modelos desenvolvidos, a utilização do XGBoost treinado com um conjunto de dados sintéticos apresentou o melhor desempenho. Além disso, sua capacidade de reproduzir a física do problema foi superior a modelos determinísticos existentes na literatura.

Faridmehr *et al.*, (2025) investigaram o comportamento de vigas com estribos reforçadas com barras longitudinais de FRP usando um conjunto de dados experimentais para avaliar a precisão de padrões internacionais. Além disso, desenvolveram um modelo de RNA com Levenberg-Marquardt para prescrever a resistência desses elementos. Quanto ao estudo das disposições normativas, o desempenho dos modelos variou significativamente, sobretudo quando há presença de estribos, com uma razão média entre os valores previstos e experimentais variando de 0,37 a 2,08. Por outro lado, o modelo de RNA desenvolvido mostrou maior precisão que as normas analisadas, até mesmo para as vigas com estribos, apresentando uma razão média entre as resistências aproximada e real de 1,02.

Oliveira *et al.*, (2024) utilizaram RNA para prever a resistência ao cisalhamento de vigas de concreto armado reforçadas com FRP, considerando diferentes variáveis de saída. Os autores perceberam que os cenários analisados apresentaram resultados mais precisos que as diretrizes existentes, sobretudo ao utilizar como variável de saída a resistência total da viga.

Os autores Wang, C. *et al.*, (2023) e Taghipour Anvari; Babanajad; Gandomi, (2023) propuseram modelos de previsão para a resistência ao cisalhamento de vigas utilizando 6 modelos de AM; e algoritmo genético, respectivamente. Os resultados obtidos possibilitaram, no primeiro estudo, identificar as variáveis mais influentes na resistência ao cisalhamento final, além de observar que os modelos apresentaram resultados superiores às equações presentes em normativas e na literatura; e permitiu a obtenção de uma equação explícita que descreve o comportamento.

Rahman; Arafin; Muntasir Billah, (2023) avaliaram o efeito do FRP e do concreto na capacidade resistente ao cisalhamento de vigas de concreto armado reforçadas. Os autores utilizaram um amplo banco de dados experimentais para diferentes diretrizes de projeto de reforço e incorporaram técnicas de AM para desenvolver um modelo de prescrição de resistência. Segundo os resultados obtidos, as características mais importantes para a resistência ao cisalhamento de vigas reforçadas com FRP são a altura das camadas de FRP e a profundidade efetiva da viga, além de uma menor relação entre o vão de cisalhamento e a altura efetiva da

viga. Além disso, os modelos existentes não apresentam bom desempenho quando aplicado em um banco de dados com grande variação nos parâmetros dos materiais, e que o modelo desenvolvido em *CatB* foi o que se adequou melhor aos dados.

Naderpour; Poursaeidi; Ahmadi, (2018) compararam algumas das equações disponíveis para determinar a resistência ao cisalhamento de vigas de concreto com barras de FRP e apresentaram um modelo em RNA para prescrever a resistência ao cisalhamento de vigas de concreto reforçadas com barras de FRP. Utilizando um modelo com uma camada oculta com 7 neurônios e 6 entradas na primeira camada, os autores obtiveram um desempenho melhor e um erro médio de 9,72%, em comparação a um erro variando de 17% a 46% para outras abordagens analisadas. Ademais, uma análise de sensibilidade indicou que a dimensão da viga é o parâmetro mais importante que afeta a resistência ao cisalhamento.

Embora a aplicação de aprendizado de máquina na predição da resistência ao cisalhamento de vigas com EB-FRP ainda careça de análises detalhadas sobre a otimização de hiperparâmetros, essa técnica apresenta alto potencial de utilização na engenharia de estruturas. As pesquisas atuais indicam que tais modelos apresentam alta competitividade com as previsões das normas e equações analíticas clássicas. Dessa forma, a integração dessas tecnologias consolida-se como uma estratégia robusta e promissora para o avanço do estudo do reforço estrutural.

4 METODOLOGIA

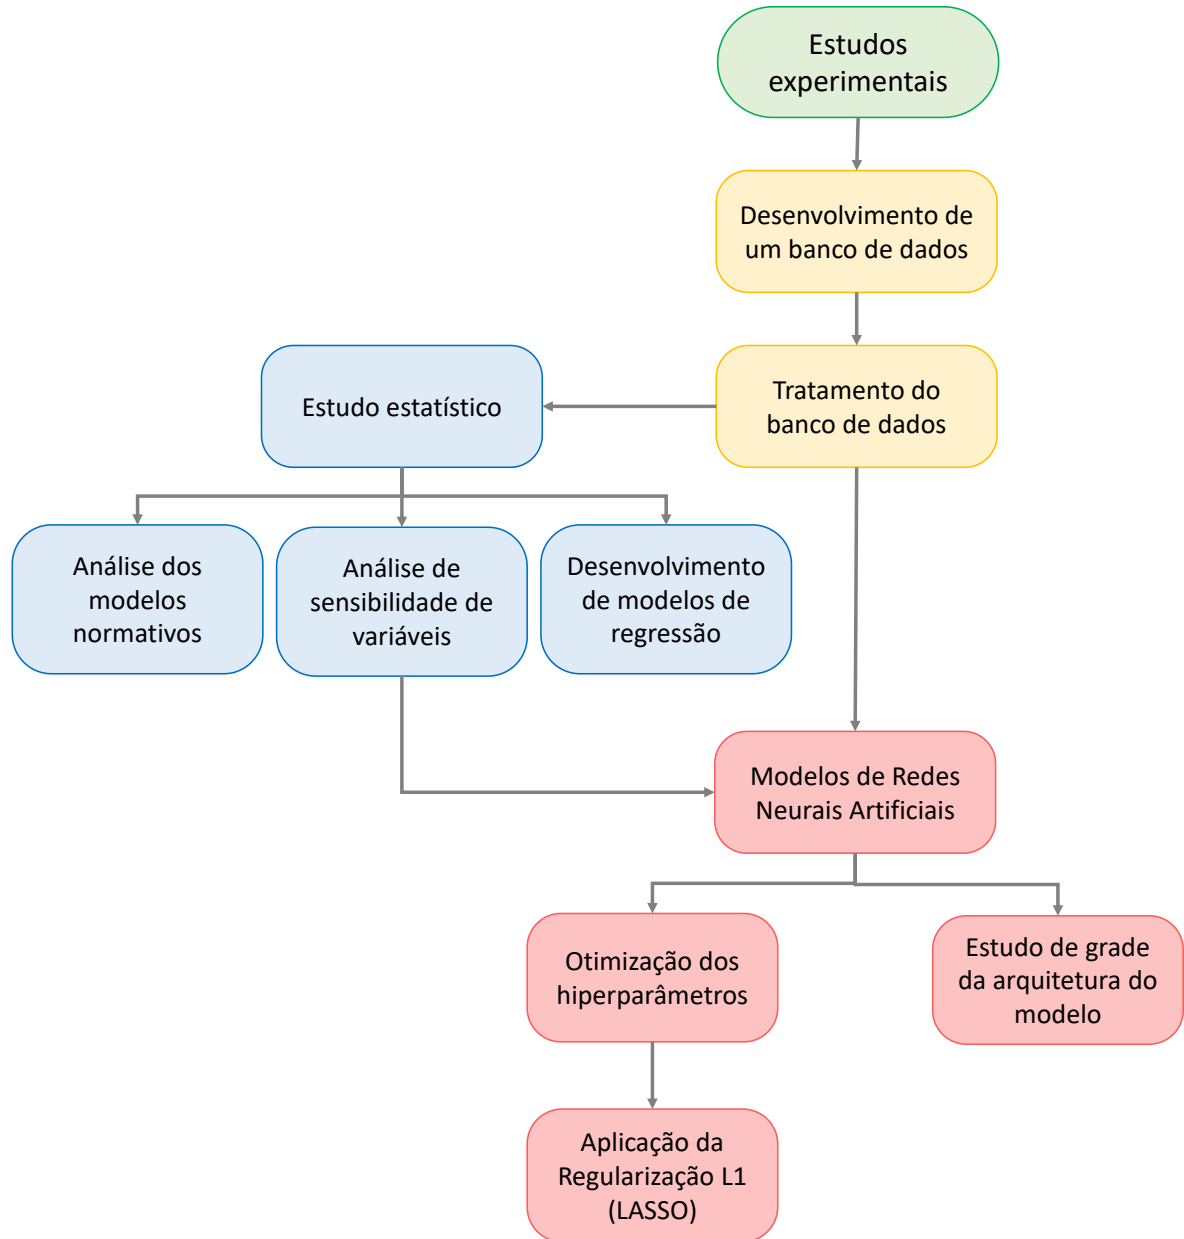
Inicialmente, foi criado um banco de dados a partir do levantamento bibliográfico realizado por Rahman, Arafin, Muntasir Billah, (2023a), Wang C. *et al.* (2023) e Oller, Kotynia e Marí (2021), compreendendo vigas de concreto armado retangulares e em seção T, com reforço nas configurações lateral, em U e totalmente envolto. Após a compilação, o banco de dados foi tratado mediante a definição de critérios de inclusão e exclusão, bem como a validação de todas as informações dos espécimes analisados.

Uma vez que o tratamento dos dados foi concluído, o produto obtido foi aplicado num estudo comparativo dos métodos de predição de resistência ao cisalhamento normativos; na análise estatística para a determinação dos parâmetros mais correlacionados com a resistência ao cisalhamento das vigas de concreto armado, utilizando os coeficientes de correlação de Pearson e Spearman; no desenvolvimento de modelos de predição baseados em regressão linear múltipla e eliminação *Backward*; e na proposição de um modelo de RNA capaz de prescrever a resistência total das vigas presentes no banco de dados. Em todas as análises, o erro envolvido foi avaliado para determinar quais métodos apresentaram resultados mais próximos àqueles obtidos experimentalmente; quais variáveis têm mais influência na resistência total das vigas de concreto armado reforçadas com FRP; e a precisão dos modelos de predição de resistência desenvolvidos pelas abordagens linear (estudo estatístico) e não linear (aplicação de redes neurais artificiais).

Por fim, foi conduzido um estudo paramétrico para otimizar os hiperparâmetros do modelo de RNA inicial. Nesta etapa, foram avaliados modelos desenvolvidos com diferentes otimizadores, taxas de aprendizado e funções de ativação, aplicando-se também técnicas de regularização, como Regularização L1 (LASSO) e *Dropout*, para mitigar o *overfitting*. Adicionalmente, um estudo de grade (*grid search*) explorou variações na arquitetura do modelo quanto ao número de camadas ocultas e neurônios. A avaliação de desempenho considerou a divisão dos dados em: 80% para treinamento (submetidos à validação cruzada com *k-folds* = 5), 10% para validação e 10% reservados para um teste cego com dados inéditos.

A Figura 8 apresenta um fluxograma que esquematiza a metodologia adotada nessa pesquisa.

Figura 8 - Fluxograma da pesquisa.

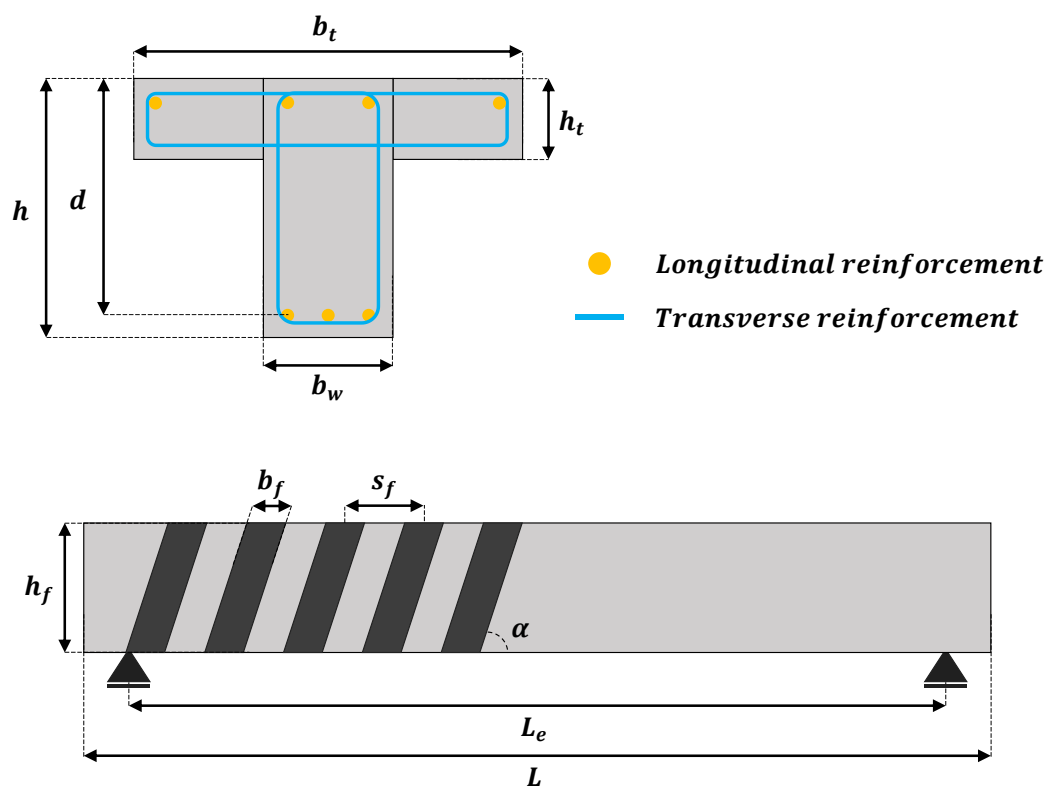


Fonte: Elaborado pelo autor.

5 BANCO DE DADOS

O banco de dados utilizado neste trabalho consiste na união dos conjuntos de dados de Rahman; Arafin; Muntasir Billah, (2023), contendo 584 vigas; Wang, C. *et al.*, (2023), contendo 442 vigas; e Oller; Kotynia; Marí, (2021), contendo 459 vigas. Os dados consistem em resultados experimentais de vigas de concreto armado reforçadas ao cisalhamento com EB-FRP. O banco de dados bruto foi previamente tratado para garantir que os valores de referência fossem consistentes e representativos. A Figura 9 apresenta uma representação esquemática das vigas reforçadas com EB-FRP e a descrição das variáveis presentes no banco de dados.

Figura 9 - Representação esquemática das vigas reforçadas com EB-FRP.



Variáveis do banco de dados

Características geométricas da viga	b_t - Largura da mesa da viga (em mm)
	h_t - Altura da mesa da viga (em mm)
	b_w - Largura da alma da viga (em mm)
	h - Altura da viga (em mm)
	d - Altura efetiva da viga (em mm)
	a/d - Relação entre o vão de cisalhamento e a altura efetiva
	L - Comprimento da viga (em mm)
	L_e - Comprimento efetiva da viga (em mm)

Continuação.

Características do concreto	f_c - Resistência à compressão do concreto (em MPa) E_c - Módulo de elasticidade do concreto (em MPa)
Características da armadura longitudinal	A_l - Área da armadura de aço longitudinal interna (em mm ²) ρ_{sl} - Taxa de armadura longitudinal interna (em %) $f_{sy,l}$ - Resistência ao escoamento do aço da armadura longitudinal interna (em MPa) $E_{sy,l}$ - Módulo de elasticidade da armadura longitudinal interna (em GPa)
Características da armadura transversal interna	$f_{sy,s}$ - Resistência ao escoamento do aço da armadura transversal interna (em MPa) $E_{sy,s}$ - Módulo de elasticidade da armadura transversal interna (em GPa) s - Espaçamento entre estribos (em mm) ρ_s - Taxa de armadura transversal interna (em %)
Características geométricas do reforço	h_f - Altura das tiras de FRP (em mm) b_f - Largura das tiras de FRP (em mm) t_f - Espessura das tiras de FRP (em mm) s_f - Espaçamento entre as tiras de FRP (em mm) ρ_f - Taxa de FRP (em %) α_f - Ângulo das tiras de FRP (em graus)
Característica do FRP	f_{fu} - Resistência última do FRP (em MPa) E_f - Módulo de elasticidade do FRP (em GPa) ε_{fu} - Deformação última do FRP
Resistência ao cisalhamento	V_{str} - Resistência das vigas sem reforço (em kN) V_{unstr} - Resistência das vigas com reforço (em kN) V_f - Acréscimo de resistência após reforço (em kN)

Fonte: Elaborado pelo autor.

Inicialmente, foram eliminados os espécimes duplicados, resultando em um total de 895 vigas. Em seguida, os estudos originais dos quais foram extraídas as informações de cada viga do banco de dados foram consultados para avaliar os seguintes pontos:

1. Confirmar se os dados presentes estavam de acordo com os trabalhos originais, realizando correções em caso de divergências;
2. Verificar a existência de informações relevantes nos trabalhos originais que não haviam sido extraídas por Rahman; Arafin; Muntasir Billah, (2023) Wang, C. *et al.*, (2023) e Oller; Kotynia; Marí, (2021);

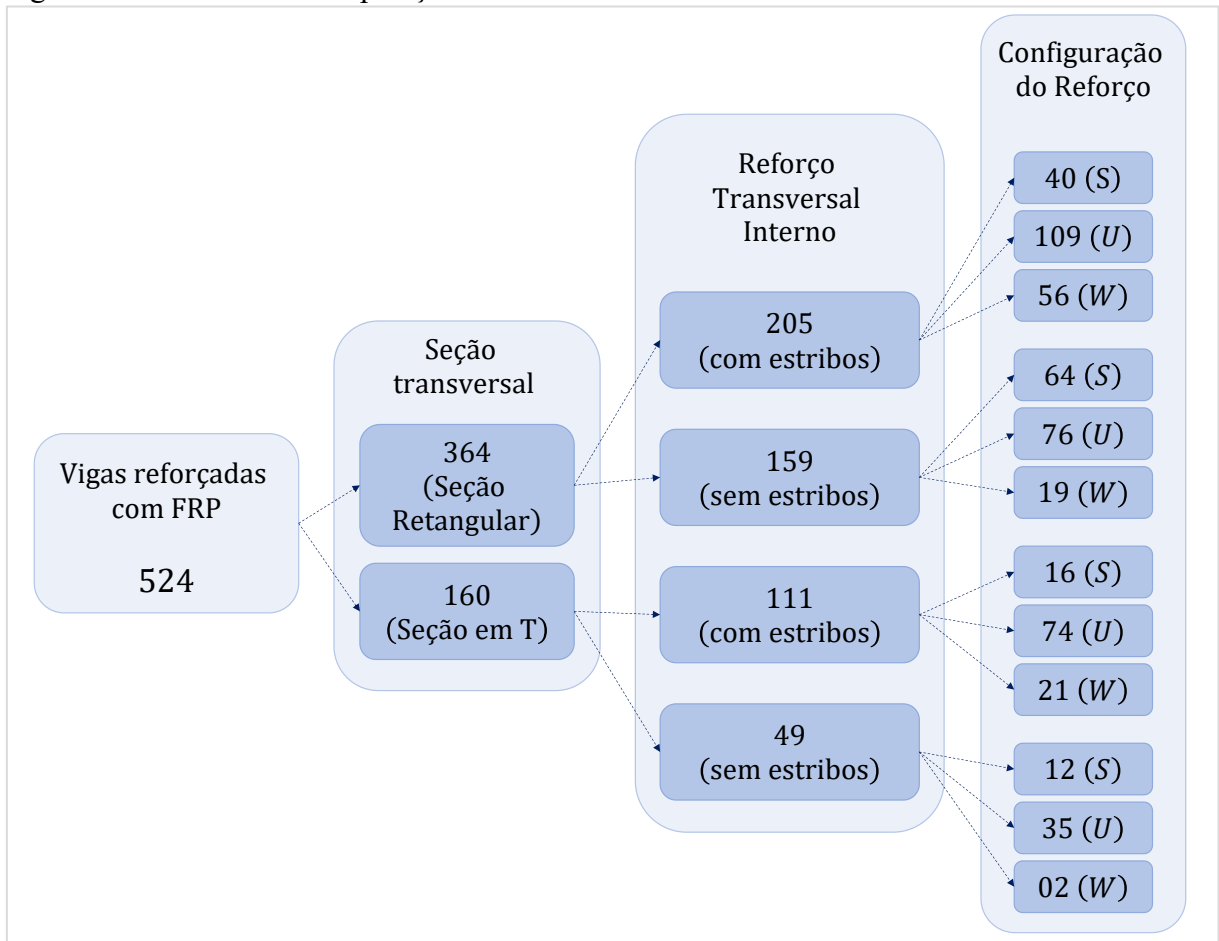
3. Assegurar que todas as vigas fossem de concreto armado, descartando casos com protensão ou cujo objetivo fosse avaliar condições específicas, como corrosão da armadura, incêndios ou ambientes de elevada agressividade;
4. Garantir que todas as vigas fossem reforçadas com EB-FRP, sem ancoragens, e empregando apenas as configurações básicas de reforço lateral, em forma de U ou por envolvimento completo;
5. Confirmar que todas as vigas apresentaram falha por cisalhamento, eliminando os casos em que ocorreram outros modos de ruptura.

As vigas que não atendiam a essas condições, bem como aquelas cujo trabalho original não pôde ser acessado, foram desconsideradas nas análises deste estudo. Inicialmente, dispunha-se de um banco de dados bruto com 895 vigas, extraídas de 243 artigos de pesquisa publicados em periódicos e anais de eventos científicos. Cada trabalho foi consultado separadamente, avaliando-se os critérios previamente estabelecidos. Vale destacar que, durante a pesquisa, o acesso a alguns trabalhos não estava disponível; em outros casos, não se encontrou registro da existência de documento que contivesse as informações indicadas na respectiva referência bibliográfica.

Assim, ao término do tratamento inicial dos dados, obteve-se um total de 524 vigas de concreto armado reforçadas com EB-FRP, compreendendo elementos de seção retangular ou em formato de T, com ou sem armadura transversal interna, e com diferentes configurações de reforço (reforço lateral, em forma de U e envolvimento completo), extraídas de 82 trabalhos científicos (Figura 10).

As variáveis descritas no banco de dados correspondem às características geométricas das vigas, às propriedades dos seus materiais constituintes (resistência à compressão do concreto e especificações das armaduras longitudinais e transversais internas), bem como às especificações do reforço de FRP e do tipo de fibra utilizada. Para garantir uniformidade de métricas entre todas as vigas, as taxas geométricas das armaduras longitudinais e transversais internas foram calculadas conforme a ABNT NBR 6118:2023, versão corrigida em 2024. Para a armadura transversal interna, consideraram-se estribos fechados de dois ramos em todas as vigas, exceto nos casos em que os autores declararam configurações distintas.

Figura 10 - Resumo da composição do banco de dados.

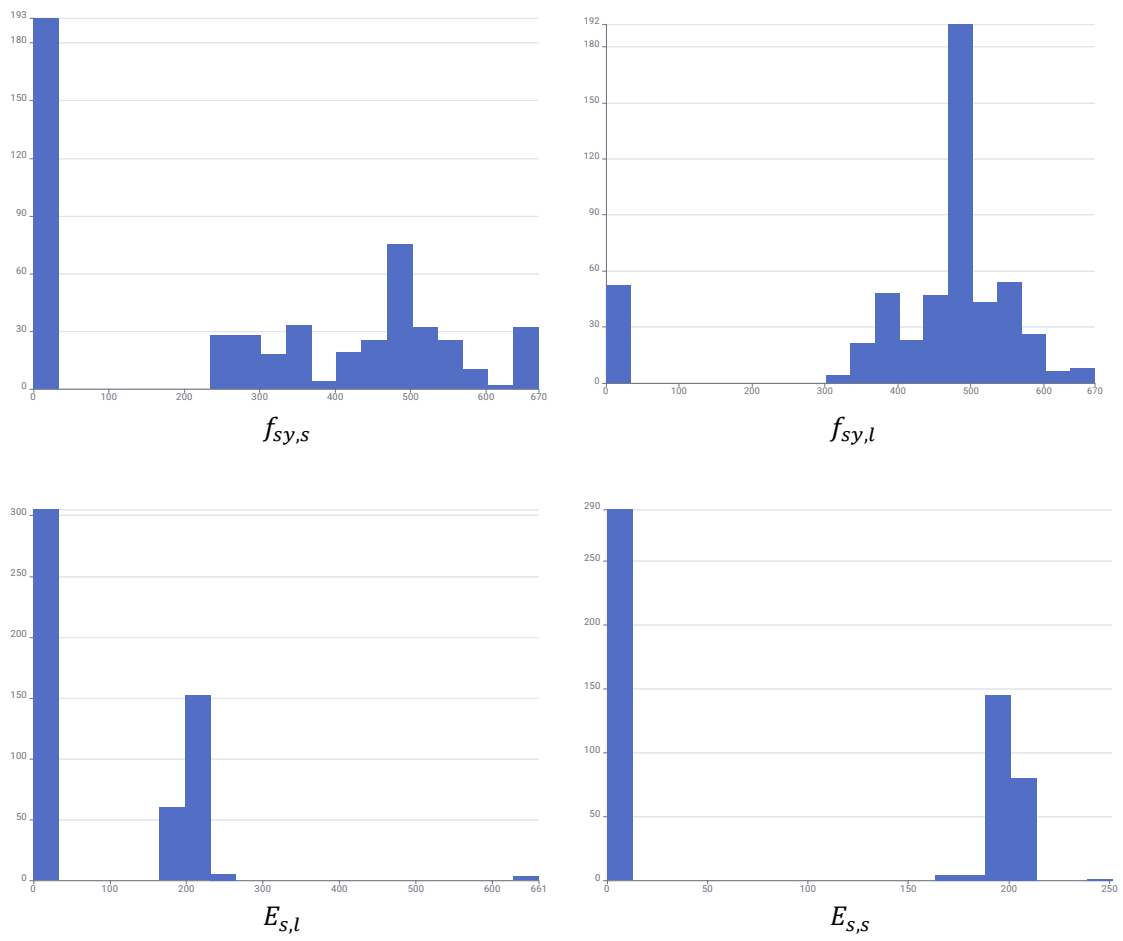


Fonte: Elaborado pelo autor.

Dentre os parâmetros que caracterizam as vigas reforçadas, a resistência ao escoamento e o módulo de elasticidade do aço das armaduras internas, bem como a deformação última do GFRP (polímero reforçado com fibra de vidro), não estavam descritos em alguns dos trabalhos originais consultados. Para suprir essas lacunas, foram construídos histogramas da resistência ao escoamento e do módulo de elasticidade considerando os valores disponíveis nas demais vigas do banco de dados. Nos casos de ausência de informação, adotaram-se valores dentro do intervalo de maior frequência com resistência ao escoamento de 500 MPa e módulo de elasticidade de 210 GPa. A Figura 11 apresenta os histogramas da resistência ao escoamento e do módulo de elasticidade do aço das armaduras longitudinal e transversal, incluindo as vigas com informações ausentes.

No caso da deformação última do GFRP, todas as vigas reforçadas com esse material apresentavam valor igual a 0,012 mm/mm, que foi adotado para os elementos sem essa informação.

Figura 11 - Resistência ao escoamento e do módulo de elasticidade do aço das armaduras longitudinal e transversal.



Fonte: Elaborado pelo autor.

6 ESTUDO ESTATÍSTICO

A Tabela 6 apresenta as medidas de resumo do conjunto de dados. Os valores unitários referentes a b_f e s_f no banco de dados indicam a presença de reforço contínuo. A capacidade resistente ao cisalhamento das vigas é usualmente definida pela superposição de três parcelas: a contribuição do concreto, a da armadura transversal interna e a do reforço de FRP. O banco de dados apresenta as resistências tanto dos elementos de referência (sem reforço) quanto dos reforçados, e a contribuição do FRP é calculada como a diferença entre a resistência do elemento reforçado e a do elemento de referência.

Tabela 6 - Descrição estatística das variáveis do banco de dados.

Parâmetro	Mínimo	Máximo	Média	Desvio-Padrão	Variância
b_t (mm)	250,00	1067,00	467,86	205,63	42282,41
h_t (mm)	50,00	178,00	95,41	35,40	1253,38
b_w (mm)	70,00	457,00	169,76	65,09	4236,09
h (mm)	110,00	934,00	351,80	140,10	19629,35
d (mm)	100,00	682,00	299,91	106,93	11434,18
a/d	0,88	5,00	2,84	0,67	0,45
L (mm)	0,00	10058,00	3006,72	1793,26	3215784,34
L_e (mm)	200,00	7315,00	2476,94	1185,17	1404633,85
f_c (MPa)	10,40	71,40	33,12	11,96	142,98
E_c (MPa)	18,06	47,32	31,69	5,88	34,55
A_l (mm ²)	0,00	12079,17	1606,23	1813,93	3290347,82
ρ_{sl} (%)	0,00	7,54	2,50	1,34	1,79
$f_{sy,l}$ (MPa)	311,22	670,00	487,30	60,65	3678,40
$E_{sy,l}$ (GPa)	180,00	661,00	209,15	35,10	1231,99
$f_{sy,s}$ (MPa)	240,00	670,00	451,37	118,65	14076,69
$E_{sy,s}$ (GPa)	165,00	251,50	204,08	7,49	56,13
s (mm)	0,00	800,00	240,78	131,54	17301,82
ρ_s (%)	0,05	2,62	0,27	0,25	0,06
h_f (mm)	110,00	762,00	306,55	125,03	15631,77
b_f (mm)	1,00	300,00	46,01	72,86	5308,44
t_f (mm)	0,01	6,00	0,59	0,82	0,67
s_f (mm)	1,00	500,00	94,09	124,87	15593,13
ρ_f (%)	0,03	9,45	0,59	1,17	1,37
α_f	45,00	90,00	82,18	16,97	287,84
f_{fu} (MPa)	13,30	4500,00	2810,39	1335,83	1784449,03

Continuação.


Parameters	Mínimo	Máximo	Média	Desvio-Padrão	Variância
E_f (GPa)	5,30	640,00	200,07	98,41	9684,96
ε_{fu}	0,00	0,07	0,02	0,01	0,00
V_{str} (kN)	8,20	813,00	138,88	122,23	14941,06
V_{unstr} (kN)	18,75	1192,00	202,63	171,82	29523,05
V_f (kN)	0,50	641,00	63,75	70,73	5002,08

Fonte: Elaborado pelo autor.

Uma vez tratado o banco de dados quanto às informações ausentes, realizou-se uma análise de correlação de variáveis para determinar as variáveis mais influentes na resistência última de vigas reforçadas. Para isso, foram construídas as matrizes de correlação considerando os coeficientes de Pearson (para avaliar o caso de houver relação linear entre os parâmetros) e de Spearman (para avaliar o caso em que os parâmetros não apresentam normalidade, nem relação linear entre eles) a partir do banco de dados estudado.

Neste estudo, considerou-se as variáveis mais correlacionadas aquelas cujo módulo do coeficiente de correlação foi maior ou igual a 0,7, assim como adotado por Wang *et al.*, (2023). Para a matriz de correlação de Pearson (Figura 12), as maiores correlações foram observadas em: b_t com o parâmetro h_t (0,96) b_w com os parâmetros h (0,77), A_l (0,79), h_f (0,71) e V_{str} (0,74); h com os parâmetros d (0,93), L (0,76), L_e (0,84), A_l (0,80), h_f (0,90), V_{str} (0,83), V_{unstr} (0,76) e V_f (0,70); d com os parâmetros L_e (0,73), h_f (0,85) e V_{str} (0,71); L com o parâmetro L_e (0,86); f_c com o parâmetro E_c (0,99); A_l com os parâmetros h_f (0,78), V_{str} (0,83), V_{unstr} (0,76) e V_f (0,71); h_f com os parâmetros V_{str} (0,80), V_{unstr} (0,72) e V_f (0,70); b_f com o parâmetro s_f (0,91); t_f com o parâmetro ρ_f (0,88); f_{fu} com o parâmetro E_f (0,70); e V_{str} com o parâmetro V_{unstr} (0,94).


Figura 12 - Matriz de Correlação de Pearson.



Fonte: Elaborado pelo autor.

Para a matriz de correlação de Spearman (Figura 13), as maiores correlações observadas foram em: b_w com o parâmetro V_{str} (0,70); h com os parâmetros L_e (0,80), h_f (0,86), V_{str} (0,76), V_{unstr} (0,71) e d (0,99); d com os parâmetros L_e (0,80), h_f (0,85) e V_{str} (0,74); L com o parâmetro L_e (0,84); f_c com o parâmetro E_c (1,00); A_l com o parâmetro V_{str} (0,74); s com o parâmetro ρ_s (-0,74); h_f com o parâmetro V_{str} (0,75); b_f com o parâmetro s_f (0,95); t_f com o parâmetro ρ_f (0,82); e V_{str} com o parâmetro V_{unstr} (0,93).

Figura 13 - Matriz de Correlação de Spearman.



Fonte: Elaborado pelo autor.

A forte correlação entre parâmetros geométricos da viga e a resistência reflete as características projeto utilizadas para o elemento e sua coerência construtiva. Em ambos os casos, observa-se que as variáveis geométricas, sobretudo b_w , d e h_f , apresentam uma relação monotônica com a variável V_{str} . Para o caso dos valores obtidos na correlação de Pearson, essa relação apresenta forte comportamento linear. Contudo, a forte correlação dessas variáveis entre si indica um problema de multicolinearidade que pode comprometer a precisão de modelos de regressão.

Um coeficiente de Spearman maior quando comparado ao coeficiente de Pearson, em valor absoluto, como observado nas relações entre ρ_s com os parâmetros b_w ($-0,51$ e $-0,31$) e d ($-0,53$ e $-0,30$), e entre o ρ_f e os parâmetros f_{fu} ($-0,58$ e $-0,35$) e

E_f ($-0,40$ e $-0,33$), indica a presença de uma relação direta e consistente, mas não necessariamente linear. Nessas situações, a correlação de Spearman mais forte sugere que a relação monotônica é mais representativa do que um modelo linear para descrever a interação entre essas variáveis.

Quanto às características que definem o reforço com EB-FRP, a relação de V_{str} com V_f é forte, mas a diferença entre os coeficientes de Spearman ($0,67$) e Pearson ($0,81$) indica que o comportamento de dependência entre essas duas variáveis pode não ser perfeitamente linear, sugerindo que, embora V_f aumente com V_{str} , a taxa de aumento pode variar. Tal fato comprova a hipótese de que a contribuição do FRP na resistência do elemento reforçado é diferente da diferença entre V_{str} e V_{unstr} , divergindo da hipótese adotada nas normativas atuais (WANG, CHENXIN *et al.*, 2023b). Um comportamento semelhante pode ser observado na correlação da resistência do elemento reforçado com os parâmetros b_f ($0,03$ e $0,33$), s_f ($0,06$ e $0,30$), ρ_f ($-0,19$ e $-0,06$), f_{fu} ($0,28$ e $0,17$) e ε_{fu} ($0,12$ e $0,04$).

6.1 Seleção de variáveis significativas

A partir das análises de correlação, as variáveis com alta correlação entre si foram eliminadas do banco de dados., a fim de evitar problemas de multicolinearidade. O critério adotado foi a identificação de coeficientes de correlação de Pearson e/ou de Spearman superiores a $0,40$, valor considerado como limite para caracterizar uma correlação moderada entre as variáveis, semelhante ao limite sugerido por (DEVORE, 2006; TABACHNICK; FIDELL, 2007). Além disso, levou-se em consideração a importância física das variáveis na descrição de vigas de concreto armado e reforço estrutural com FRP.

A seleção das variáveis foi realizada com base nas considerações seguintes:

- Nas características geométricas da viga, para fins de generalidade, foram descartados os parâmetros b_t e h_t , adotando apenas a variável b_w que descreve a largura das vigas de seção retangular;
- Os parâmetros h e L foram desconsiderados por apresentarem redundância com os parâmetros d e L_e , respectivamente;
- Eliminou-se o E_c , mantendo-se apenas o f_c , embora apresentasse baixa correlação com a resistência ao cisalhamento, devido sua relevância e aplicabilidade nas normativas de projeto estrutural;
- O parâmetro A_l foi eliminado por estar embutido no cálculo de ρ_l ;

- O parâmetro s foi eliminado, por estar embutido no cálculo de ρ_s ; e o $E_{sy,s}$, em virtude de sua baixa variação;
- Descartou-se o t_f devido à sua alta correlação com os parâmetros s_f e ρ_f ;
- O parâmetro E_f foi eliminado em razão de sua alta correlação com o f_{fu} ;
- O parâmetro h_f foi descartado em virtude de sua alta correlação com o d .

Embora os pares b_f/s_f e f_{ffu}/ε_{fu} apresentem correlação, eles foram mantidos por representarem grandezas distintas e relevantes para o comportamento mecânico do elemento reforçado. Os parâmetros resultantes foram apresentados na Tabela 7.

Tabela 7 - Variáveis mais significativas.

Características geométricas da viga	b_w - Largura da alma da viga (em mm) d - Altura efetiva da viga (em mm) a/d - Relação entre o vão de cisalhamento e a altura efetiva L_e - Comprimento efetiva da viga (em mm)
Características do concreto	f_c - Resistência à compressão do concreto (em MPa)
Características da armadura longitudinal	ρ_{sl} - Taxa de armadura longitudinal interna (em %) $f_{sy,l}$ - Resistência ao escoamento do aço da armadura longitudinal interna (em MPa) $E_{sy,l}$ - Módulo de elasticidade da armadura longitudinal interna (em GPa)
Características da armadura transversal interna	$f_{sy,s}$ - Resistência ao escoamento do aço da armadura transversal interna (em MPa) ρ_s - Taxa de armadura transversal interna (em %)
Características geométricas do reforço	b_f - Largura das tiras de FRP (em mm) s_f - Espaçamento entre as tiras de FRP (em mm) ρ_f - Taxa de FRP (em %) α_f - Ângulo das tiras de FRP (em graus)
Característica do FRP	f_{fu} - Resistência última do FRP (em MPa) ε_{fu} - Deformação última do FRP
Variáveis de saída	V_{str} - Resistência das vigas sem reforço (em kN)

Fonte: Elaborado pelo autor.

6.2 Análises de regressão de variáveis

A resistência ao cisalhamento das vigas de concreto armado reforçadas com EB-FRP (V_{str}) foi modelada por meio de regressão linear múltipla, utilizando as variáveis listadas na Tabela 7 como preditores. A seleção dos parâmetros que compõem a formulação final, bem como o diagnóstico do modelo, baseou-se no critério de significância estatística (DEVORE, 2006; TABACHNICK; FIDELL, 2007), visando identificar as variáveis com maior impacto na resistência do elemento e assegurar o melhor ajuste aos dados experimentais.

Nesta etapa, utilizou-se um subconjunto dos dados referente às vigas reforçadas com polímeros reforçados com fibra de carbono (CFRP) contendo 446 espécimes. A seleção restringiu-se a esses elementos devido a aplicabilidade das normas ACI 440.2R-17 (ACI, 2017), fib Bulletin 14, (2001) e fib Bulletin 90 (BALÁZS *et al.*, 2019), cujas formulações e prescrições de projeto são voltadas a este grupo específico de materiais.

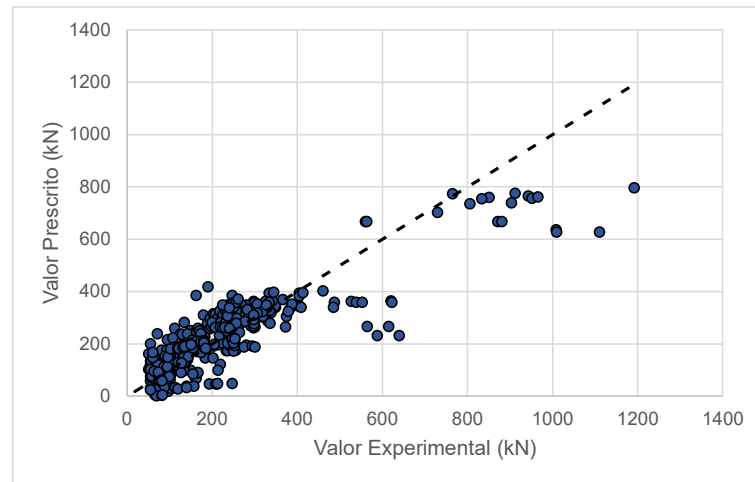
Os resultados da regressão linear múltipla indicaram um ajuste satisfatório (Tabela 8 e Figura 14), com um coeficiente de correlação R^2 de 0.7416, e a análise de variância (ANOVA) confirmou a significância global do modelo, por apresentar um valor-p < 0.001 (nível de significância inferior a 0.05). Dentre as variáveis independentes, as características geométricas da seção (b_w , d e a razão a/d), a resistência à compressão do concreto (f_c) e a taxa de reforço de FRP (ρ_f) apresentaram os menores valores-p, consolidando-se como os preditores de maior impacto. Por outro lado, variáveis como o módulo de elasticidade da armadura longitudinal ($E_{s,l}$) e a taxa de estribos transversais (ρ_s) não apresentaram significância estatística, com valores-p superiores ao limite adotado.

Tabela 8 - Regressão linear múltipla com 16 preditores.

Estatística de regressão					
R múltiplo					0,8665
R-Quadrado					0,7508
R-quadrado ajustado					0,7415
Erro padrão					91,1530
Observações					446
ANOVA					
	gl	SQ	MQ	F	F de significação
Regressão	16	10741591	671349,40	80,80	0,00
Resíduo	429	3564506	8308,87		
Total	445	14306097			

Fonte: Elaborado pelo autor.

Figura 14 - Ajuste do modelo com 16 preditores aos dados experimentais




Fonte: Elaborado pelo autor.

Para o ajuste do modelo, foi aplicado o método de eliminação *Backward*. Este processo consiste em remover iterativamente a variável menos significativa do modelo de regressão linear múltipla (isto é, aquela com o maior p-valor), desde que seu valor seja superior ao critério de exclusão, estabelecido em um nível de significância estatística de 0.05. O procedimento é repetido até que todas as variáveis preditoras restantes no modelo sejam estatisticamente significativas.

Neste estudo, foram avaliados 6 modelos, nomeados em Mn, onde n representa o número de preditores daquele modelo. A Tabela 10 apresenta os modelos avaliados, os preditores utilizados em cada um deles e seu respectivo valor-p. O resumo estatístico das regressões resultantes é apresentado na Tabela 9, e a Figura 15 ilustra os respectivos gráficos de dispersão.

Figura 15 - Predição dos modelos de regressão.



Continuação.

Variáveis	Número de variáveis					
	M16	M15	M14	M13	M12	M11
ρ_l	0,00	0,00	0,00	0,00	0,00	0,00
$f_{sy,l}$	0,00	0,00	0,00	0,00	0,00	0,00
$E_{s,l}$	0,94	*	*	*	*	*
$f_{sy,s}$	0,38	0,38	0,39	*	*	*
ρ_s	0,24	0,24	0,25	0,05	0,06	0,05
b_f	0,17	0,16	0,02	0,02	0,02	0,02
s_f	0,69	0,69	*	*	*	*
ρ_f	0,04	0,04	0,03	0,02	0,03	0,03
α_f	0,00	0,00	0,00	0,00	0,00	0,00
f_{fu}	0,35	0,35	0,34	0,42	*	*
ε_{fu}	0,31	0,31	0,30	0,30	0,45	*


* Variável eliminada do modelo de regressão.

Fonte: Elaborado pelo autor.


É importante destacar que um valor-p elevado não implica, necessariamente, que a variável seja irrelevante para a física do fenômeno, mas pode indicar que a amostra disponível é excessivamente homogênea quanto a esse parâmetro. Tal comportamento foi observado na taxa geométrica de estribos (ρ_s), que apresentou um valor-p de 0,24 apesar de sua importância teórica na resistência ao cisalhamento. Conforme a

Figura 16, a elevada concentração de espécimes com baixas taxas de estribos ou sem armadura transversal limita a sensibilidade do modelo de regressão em capturar a influência dessa variável em razão da sua baixa variabilidade. Em contrapartida, as variáveis que exibiram significância estatística foram aquelas que apresentaram maior variabilidade e distribuição mais abrangente no banco de dados, como as variáveis geométricas.

Figura 16 - Histograma das variáveis b_w , d , a/d e ρ_s .



Continuação.



Fonte: Elaborado pelo autor.

Com base nos valores de R^2 ajustado, os modelos demonstraram um nível de ajuste similar. Foi observado um ajuste ligeiramente aprimorado à medida que as variáveis predictoras com maiores valores do p-valor foram sucessivamente eliminadas. Embora os valores de R^2 ajustado sejam muito próximos, o modelo contendo 11 variáveis destaca-se devido à sua maior simplicidade. Este modelo atinge um poder explicativo ligeiramente superior ao dos demais, mas com um número consideravelmente menor de preditores.

A análise da Figura 15 revela que as curvas dos seis modelos preditivos apresentam comportamentos análogos, o que reforça a capacidade preditiva do modelo com 11 variáveis, cuja formulação matemática é apresentada na Equação 6.1. Além disso, observa-se que, embora cada abordagem apresente particularidades, os seis métodos demonstraram maior acurácia na predição de valores de resistência inferiores a 400 kN. Para valores superiores, verificou-se um aumento tanto no erro quanto na dispersão dos valores previstos, tendência que se acentua com o incremento da resistência. Tal comportamento é justificado pela natureza dos dados utilizado

para a construção dos modelos, em que cerca de aproximadamente 91,93 % das vigas reforçadas com fibra de carbono apresentam resistência inferior a 400 kN. Em razão disso, os modelos desenvolvidos exibem maior precisão na predição de valores de resistência nesse intervalo do que para vigas com resistências ao cisalhamento superiores.

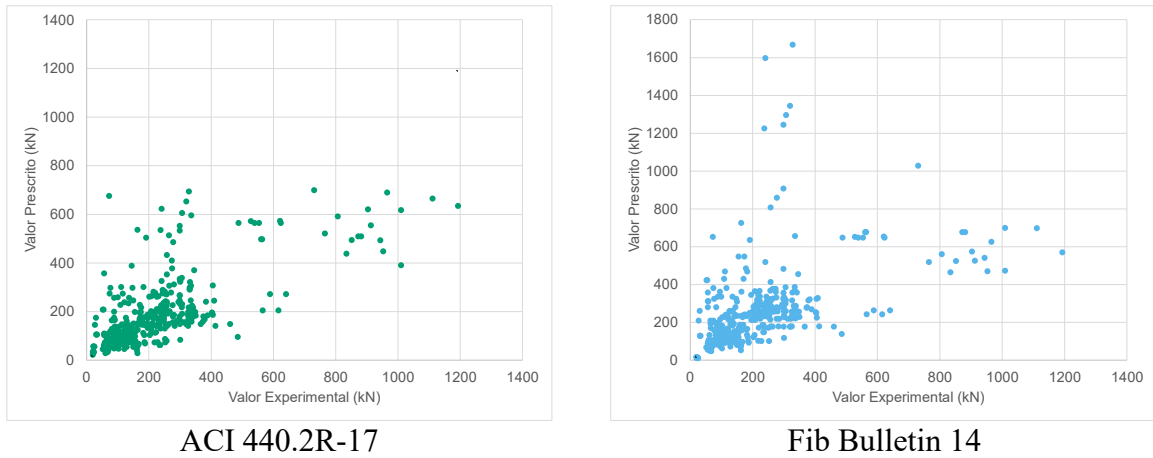
$$\begin{aligned}
 V_n = & 1,18b_w + 0,73d + 0,01L_e - 63,76(a/d) + 1,51f_c + 25,17\rho_l \\
 & - 0,24f_{sy,l} + 36,97\rho_s + 0,17b_f + 1006,59\rho_f + 0,78\alpha_f \quad \text{Equação 6.1} \\
 & - 144,34
 \end{aligned}$$

6.3 Acurácia do modelo proposto

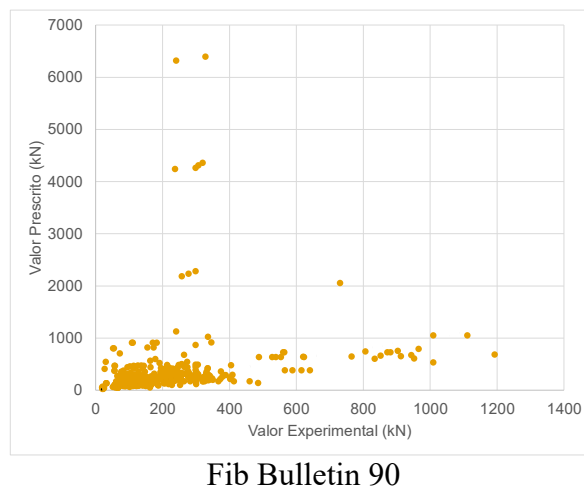
A acurácia do modelo M11 foi avaliada com base nas normativas ACI 440.2R-17 (ACI, 2017), FIB BULLETIN 14, (2001) e fib Bulletin 90 (BALÁZS *et al.*, 2019), em que seus respectivos diagramas de dispersão são apresentados na Figura 17. Esses documentos apresentam procedimentos particulares para a prescrição da resistência ao cisalhamento de elementos reforçados com FRP. As normas ACI 440.2R-17 (ACI, 2017), FIB BULLETIN 14, (2001) tiveram seu desenvolvimento fundamentado na analogia da treliça de Morsch, considerando a resistência total da viga como o somatório das componentes de resistência do concreto, do aço e do reforço. No caso da FIB BULLETIN 14, (2001), as deformações efetivas no FRP são definidas por meio de expressões empíricas obtidas experimentalmente.

A fib Bulletin 90 (2019), além de apresentar a metodologia para estudo das contribuições do concreto, dos estribos e do FRP na resistência do elemento reforçado, é destacada a necessidade de considerar os efeitos de componentes resistentes ocasionadas por protensão ou membros com seção variável. Ademais, para membros que possuem estribos, a contribuição do concreto é desprezada.

Figura 17 - Gráficos de dispersão das normativas internacionais.



Continuação.

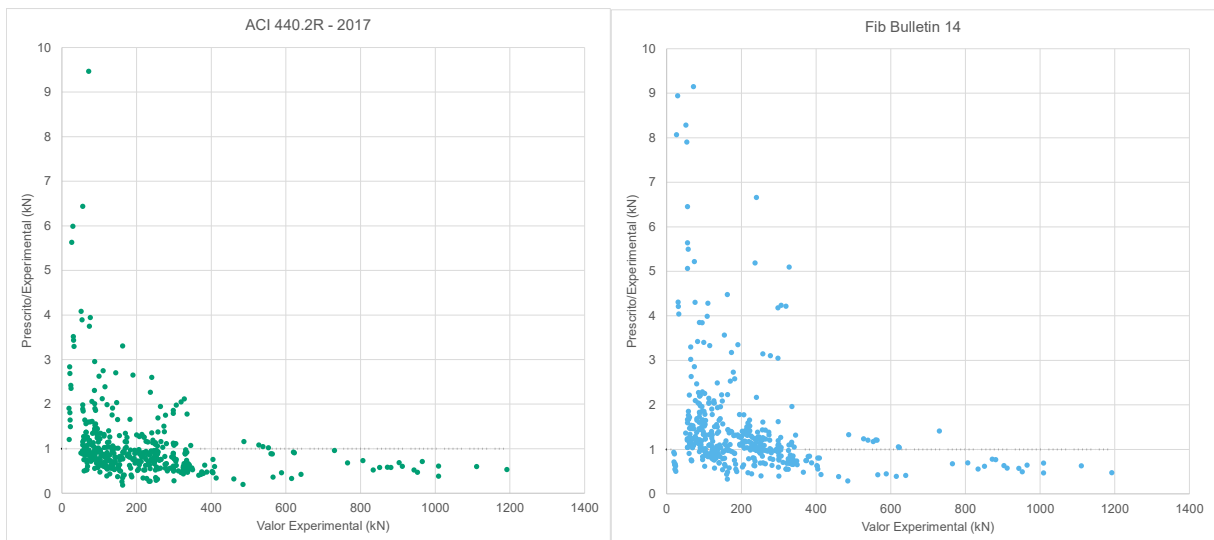


Fonte: Elaborado pelo autor.


A análise dos diagramas de dispersão das normativas, bem como a razão entre as resistências (Figura 18) permite observar uma grande dispersão nos valores prescritos, sobretudo na predição de resistências superiores a 400kN. Esse comportamento também foi observado nos modelos criados. O ajuste das predições obtidas a partir das normativas ACI 440.2R-17 (ACI, 2017), FIB BULLETIN 14, (2001) e fib Bulletin 90 (BALÁZS *et al.*, 2019) é apresentado na Figura 18. O coeficiente de correlação R^2 foram, respectivamente, 0,5199,

0,2785 e 0,0625. Para o FIB BULLETIN 14, (2001) e do fib Bulletin 90 (BALÁZS *et al.*, 2019), identificaram-se previsões consideravelmente altas para algumas vigas com resistências experimentais inferiores a 400 kN.

Figura 18 - Predição de resistência com base nas normativas internacionais e regressão linear.



Continuação.



Fonte: Elaborado pelo autor.

O reduzido valor de R^2 obtido para as normativas é justificado pela alta dispersão de suas prescrições e presença de *outliers*. Os desvios-padrão para a ACI 440.2R-17, FIB BULLETIN 14, (2001) e a fib Bulletin 90 (2019) foram de 139,76, 205,22 e 612,72, respectivamente. Em contrapartida, o modelo M11 apresentou um coeficiente de correlação superior e um desvio-padrão de 155,24, o que representa uma redução de aproximadamente

51,42% em relação à média das normas internacionais. Quanto ao erro absoluto médio, o modelo M11 obteve valores 22,55%, 37,28% e 66,97% menores do que os registrados pelas normativas ACI 440.2R-17, FIB BULLETIN 14, (2001) e a fib Bulletin 90 (2019).

6.4 Discussão dos resultados obtidos via regressão

Este capítulo descreveu o desenvolvimento de um amplo banco de dados de vigas de concreto armado reforçadas ao cisalhamento com EB-FRP. Após o levantamento bibliográfico, os dados foram verificados em suas fontes e tratados para garantir a consistência das informações. Foram realizadas, então, análises estatísticas e de sensibilidade das variáveis envolvidas, seguidas pela aplicação do modelo de regressão linear múltipla com eliminação *Backward*. Esse processo permitiu o desenvolvimento de um modelo capaz de estimar a resistência ao cisalhamento das vigas de forma satisfatória por meio de regressão linear múltipla.

O banco de dados consolidado totalizou 524 vigas de concreto armado reforçadas com FRP, extraídas de 82 trabalhos científicos. A amostra contemplou seções retangulares e em T, com ou sem armadura transversal interna, abrangendo três configurações de reforço: lateral, em forma de U e envolvimento completo. A análise de sensibilidade, realizada no subconjunto de vigas reforçadas com fibra de carbono, permitiu identificar as características mais significativas para o comportamento estrutural por meio do estudo de correlações. Esse procedimento resultou em uma redução na dimensionalidade do problema, passando de 30 variáveis iniciais para as 17 mais relevantes, eliminando-se parâmetros pouco relacionados ou redundantes.

A análise de correlação demonstrou que os parâmetros b_w , h , d , A_l e h_f possuem alta correlação com a resistência do elemento reforçado com FRP (V_{str}). Embora as formulações da ACI 440.2R-17 e FIB BULLETIN 14, (2001) utilizem b_w , d e h_f em seus cálculos, ambas negligenciam parâmetros relativos à armadura longitudinal interna. A relevância dessa variável foi confirmada pelas análises de regressão, nas quais a taxa geométrica e a resistência ao escoamento do aço da armadura longitudinal foram selecionadas como variáveis preditoras essenciais nos modelos desenvolvidos. Além disso, verificou-se que a contribuição do FRP na resistência ao cisalhamento da viga (V_f) exibe uma relação monotônica com V_{str} e V_{unstr} , mas o comportamento não é linear.

Com base nos parâmetros mais significativos, aplicou-se um modelo de regressão linear múltipla para determinar uma formulação capaz de estimar a resistência ao cisalhamento dos elementos. O modelo obtido apresentou alta significância estatística, com desempenho superior para valores de resistência inferiores a 400 kN. Posteriormente, a técnica de eliminação *Backward* foi empregada para ajustar o modelo, removendo sucessivamente os preditores menos significativos com base em seus respectivos valores-p.

Os modelos de predição apresentaram comportamentos semelhantes e níveis de significância próximos. De modo geral, verificou-se maior precisão para carregamentos de até 400 kN, com um incremento do erro nas previsões de resistências superiores. Essa tendência decorre de o banco de dados ser composto predominantemente por vigas nessa faixa de carga. Entre os resultados, o modelo M11 destacou-se por alcançar um desempenho levemente superior aos demais, apresentando a vantagem adicional de utilizar menos variáveis.

Por fim, verificou-se que as formulações normativas atuais possuem limitada capacidade preditiva para a resistência ao cisalhamento de vigas reforçadas com FRP, evidenciada pela alta dispersão dos resultados. Em contrapartida, os modelos desenvolvidos via regressão linear múltipla atingiram o objetivo proposto, superando as normas internacionais em precisão e apresentando desvios-padrão significativamente menores. Tais resultados ratificam a eficácia do modelo proposto, especialmente pela inclusão de variáveis da armadura longitudinal, consolidando-o como uma alternativa robusta para a estimativa da capacidade resistente dessas estruturas.

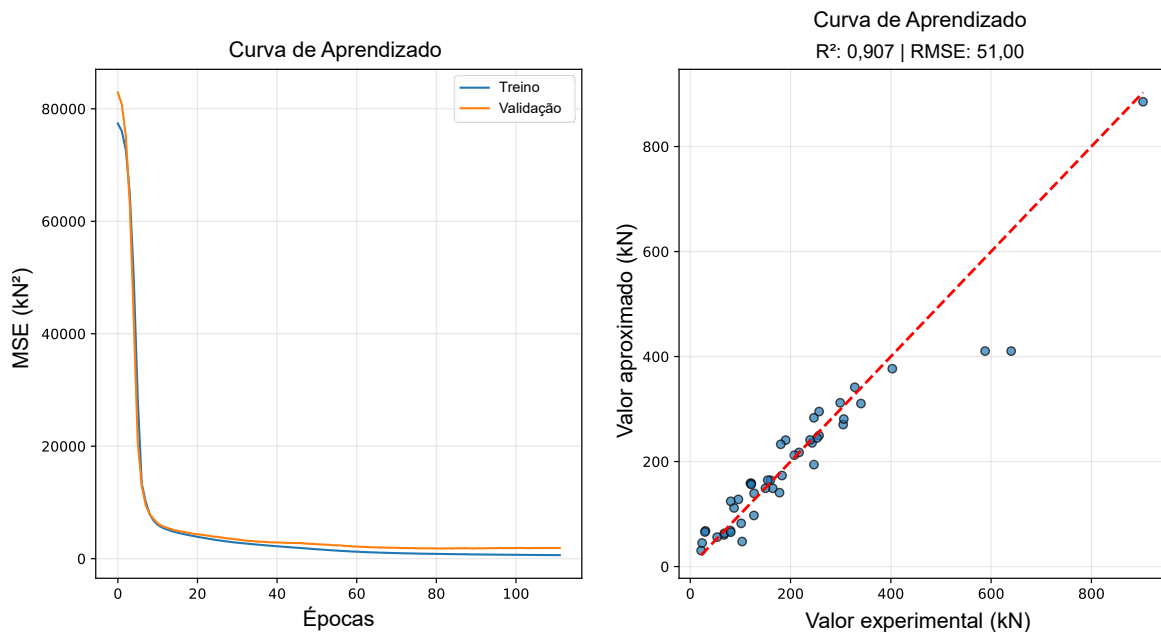
7 MODELO DE REDES NEURAIS ARTIFICIAIS

Os modelos de RNA avaliados neste trabalho partiram de um modelo base correspondente à uma adaptação da arquitetura proposta por Oliveira *et al.*, (2024) para prever a resistência ao cisalhamento total de vigas reforçadas com EB-FRP (V_{str}), relativo ao Cenário II analisado pelo autor. A topologia da rede compreende uma camada de entrada, duas camadas ocultas com 15 e 12 neurônios, respectivamente, e uma camada de saída. Nas camadas ocultas, adotou-se a função de ativação RELU, empregando-se o otimizador Adam com taxa de aprendizado de 0,01. Para garantir a convergência adequada, as variáveis numéricas foram submetidas à padronização (*StandardScaler*) e as variáveis categóricas à codificação *One-Hot*.

A estratégia de validação consistiu em duas etapas. Inicialmente, aplicou-se o método de validação cruzada (*cross-validation*) com 5 partições ($k = 5$) para mensurar as métricas médias de desempenho (R^2 e RMSE). Posteriormente, realizou-se uma divisão do conjunto de dados na proporção de 80% para treino, 10% para validação e 10% para teste. A parcela de validação foi utilizada para monitoramento do critério de parada *Early Stopping*, configurado com tolerância de 30 épocas e recuperação dos melhores pesos, a fim de mitigar o *overfitting*. Os parâmetros de entrada utilizados foram as variáveis apresentadas na Tabela 7. Além destas, foram acrescentados como o tipo de reforço (lateral, em forma de U ou envolvimento completo), a presença de estribos e a continuidade do reforço (reforço contínuo ou discreto).

O modelo desenvolvido alcançou um coeficiente de determinação (R^2) de 0,9075 e RMSE de 51,00 kN (Figura 19). Observou-se uma maior dispersão nas predições para resistências superiores a 400 kN, o que é coerente com a escassez de dados experimentais superiores a essa faixa de resistência. Em comparação às formulações normativas, o desempenho do modelo base foi significativamente superior. Enquanto o ACI 440.2R-17 (ACI, 2017), fib Bulletin 14, (2001) e o fib Bulletin 90 (BALÁZS *et al.*, 2019) apresentaram valores de R^2 de 0,5199, 0,2785 e 0,0625, respectivamente, o modelo proposto obteve um ganho de desempenho de até 0,8450 pontos em relação às normas tradicionais.

Figura 19 - Desempenho do modelo inicial.



Fonte: Elaborado pelo autor.

Após a validação do modelo base, realizou-se o refinamento dos hiperparâmetros visando maximizar a acurácia da RNA. Nesse processo, foram criados diversos modelos derivados do modelo base, alterando-se um hiperparâmetro por vez em relação à configuração original. É importante ressaltar que essas análises foram independentes e não cumulativas, ou seja, para cada novo teste, retomou-se o modelo base. Os parâmetros avaliados isoladamente foram: otimizador, taxa de aprendizado, função de ativação e *Dropout* em diferentes intensidades. Adicionalmente, investigou-se o impacto da profundidade da rede através da inserção de duas camadas ocultas. Por fim, aplicou-se a Regularização LASSO visando realizar um estudo de sensibilidade das variáveis de entrada.

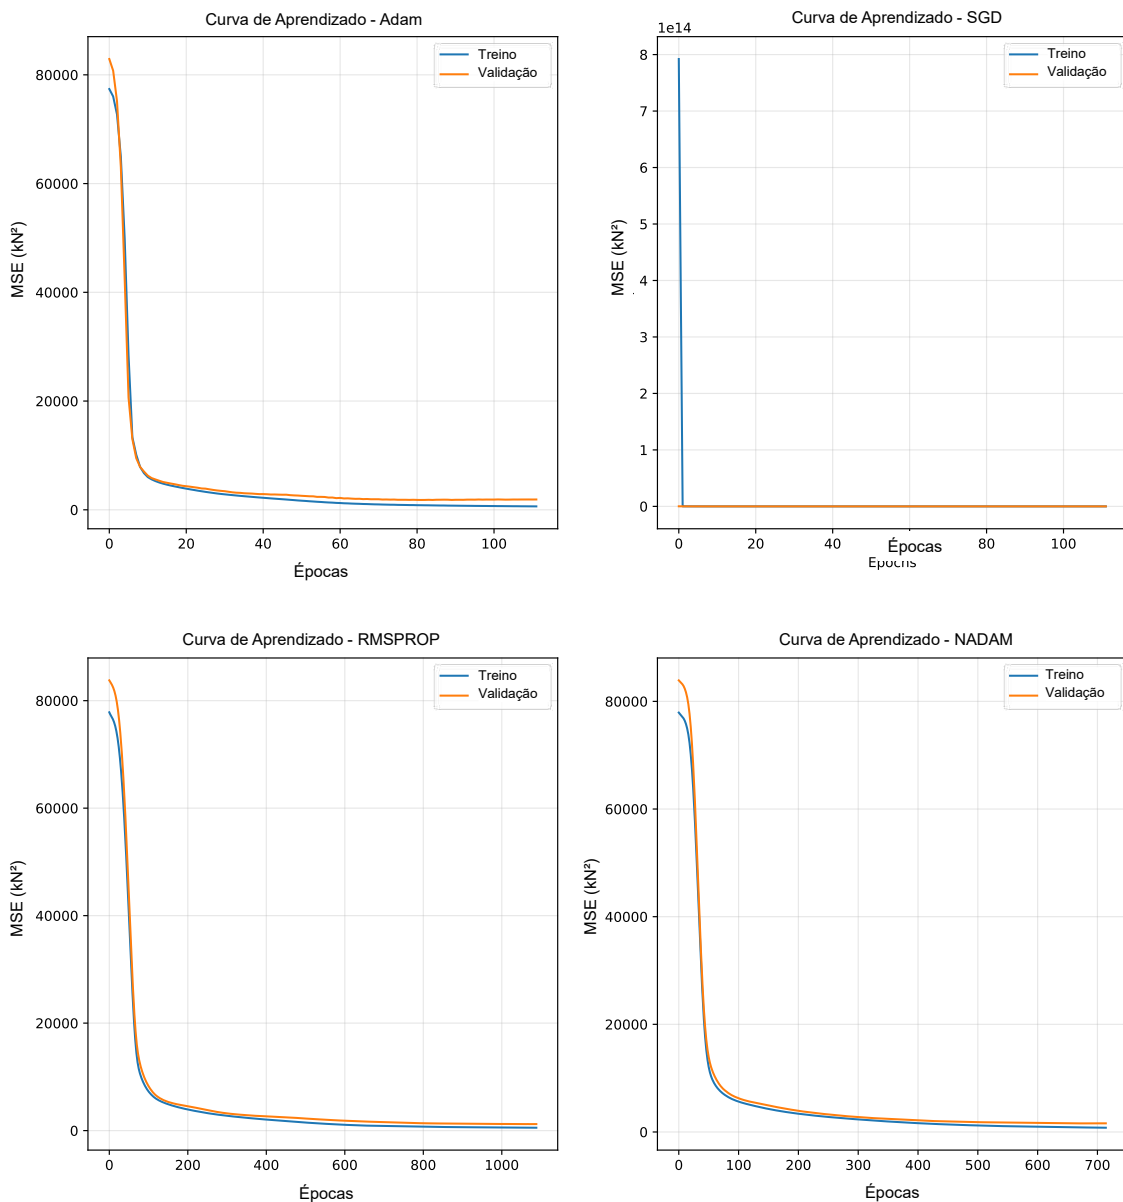
7.1 Ajuste dos hiperparâmetros da RNA

Inicialmente, avaliaram-se os otimizadores Adam (*Adaptive Moment Estimation*), RMSprop (*Root Mean Square Propagation*), SGD (*Stochastic Gradient Descent*) e Nadam (*Nesterov-accelerated Adaptive Moment Estimation*). A análise das curvas de aprendizado (Figura 20) demonstrou diferenças significativas na eficiência computacional. Enquanto o otimizador RMSprop exigiu cerca de 1100 épocas e o Nadam cerca de 700 épocas para estabilização, o Adam atingiu a convergência em, aproximadamente, 110 épocas. Em termos

de métricas de desempenho finais (Tabela 11), Nadam e RMSprop apresentaram precisão próximas.

Em contrapartida, o otimizador SGD não obteve convergência adequada, resultando em valores negativos de R^2 , indicando incapacidade de ajuste aos dados. Uma provável razão para essa falha é a alta sensibilidade do SGD à taxa de aprendizado inicial e à topologia da superfície de erro. Devido à utilização de uma taxa fixa, o algoritmo provavelmente ficou preso em mínimos locais, enquanto os métodos adaptativos ajustaram-se melhor. Considerando, à sua velocidade de treinamento, o Adam foi selecionado como melhor otimizador.

Figura 20 - Curvas de aprendizado para os otimizadores.



Fonte: Elaborado pelo autor.

Tabela 11 - Teste de otimizadores.

Otimizador	Validação		Teste cego	
	R ²	RMSE (kN)	R ²	RMSE (kN)
Adam	0,8881	52,25	0,9075	51,00
RMSprop	0,9083	44,91	0,9548	35,63
SGD	Modelo não convergiu		Modelo não convergiu	
Nadam	0,9307	43,40	0,9454	39,19

Fonte: Elaborado pelo autor.

A análise da taxa de aprendizado foi realizada considerando os valores de 0,1, 0,01, 0,001 e 0,0001. A Tabela 12 e a Figura 21 apresentam, respectivamente, as curvas de aprendizagem e as métricas de desempenho dos modelos para as taxas de aprendizado avaliadas. A taxa de 0,1 demonstrou uma convergência muito rápida, acionando o critério de parada com poucas épocas, sugerindo instabilidade na busca pelo mínimo global. Por outro lado, a taxa de 0,0001 apresentou convergência excessivamente lenta. O modelo atingiu o limite máximo de 2000 épocas estabelecido no treinamento sem acionar o critério de estabilidade, indicando subutilização da capacidade de aprendizado dentro do tempo hábil.

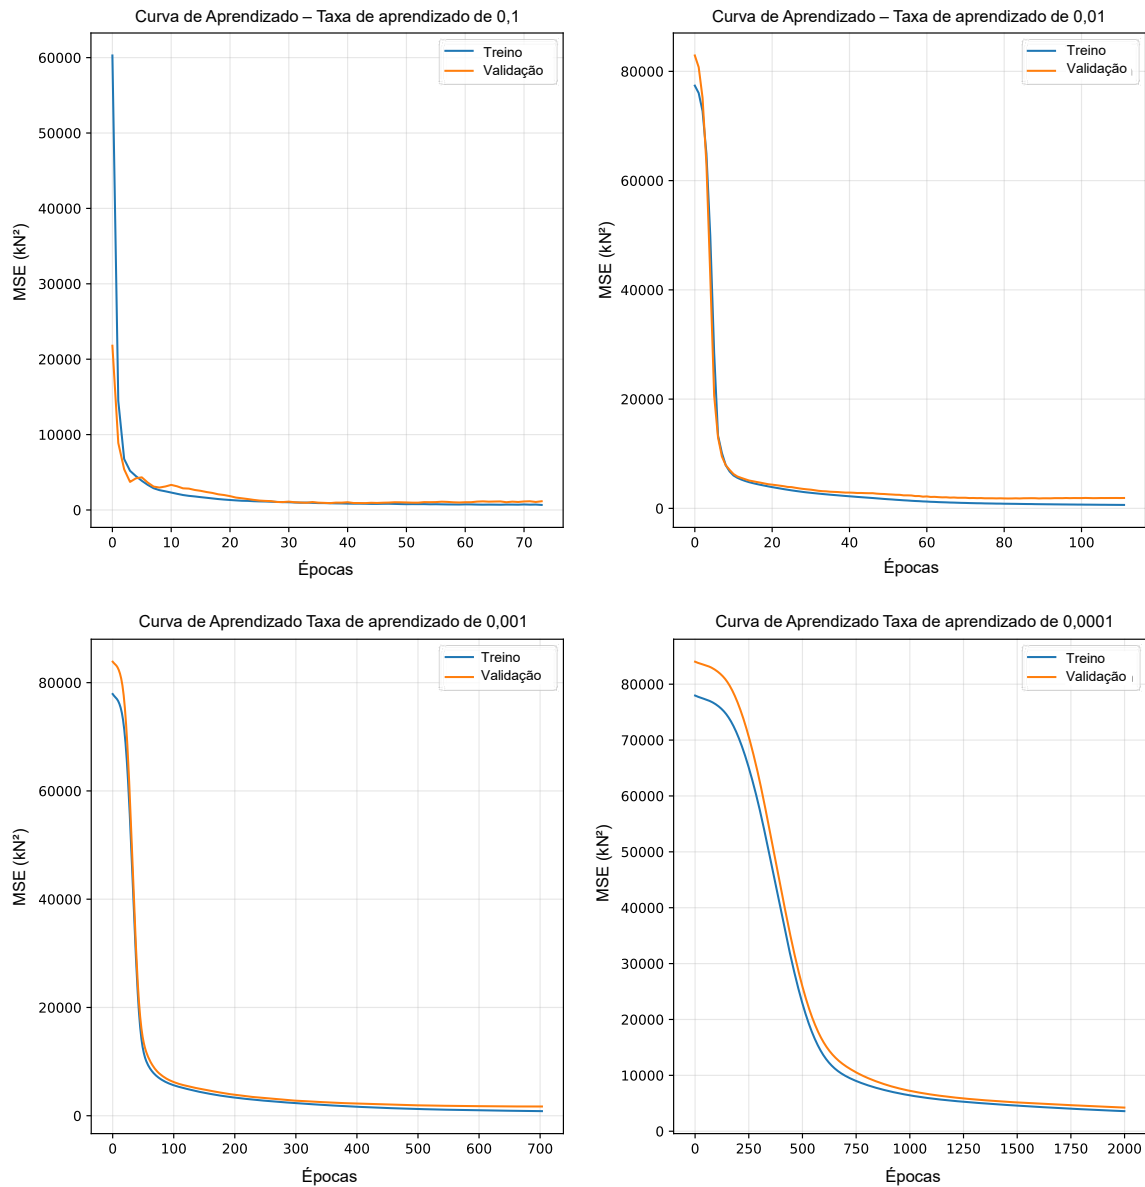
As taxas de 0,01 e 0,001 apresentaram curvas de decaimento do erro suaves e estáveis, atingindo valores finais de MSE equivalentes. Quanto ao tempo de convergência, enquanto o modelo com taxa de 0,001 demandou cerca de 700 épocas para estabilização, o modelo com taxa de 0,01 convergiu com aproximadamente 110 épocas. Com base nos resultados obtidos, optou-se pela taxa de aprendizado de 0,001 devido ela apresentar o melhor equilíbrio entre as métricas de erro e correlação. Essa configuração atingiu um R² superior a 0,90, além de manter um desempenho consistente nos modelos de validação e teste.

Tabela 12 - Teste da taxa de aprendizado.

Taxa de aprendizado	Validação		Teste cego	
	R ²	RMSE (kN)	R ²	RMSE (kN)
0,1	0,7870	61,77	0,9596	33,70
0,01	0,8881	52,25	0,9075	51,00
0,001	0,9254	44,47	0,9494	37,72
0,0001	0,8353	67,31	0,7516	83,56

Fonte: Elaborado pelo autor.

Figura 21 - Curvas de aprendizagem para diferentes taxas de aprendizado.



Fonte: Elaborado pelo autor.

As funções de ativação avaliadas compreenderam a Sigmoide; Tangente hiperbólica (TANH); *Rectified Linear Unit* (RELU); *Exponential Linear Unit* (ELU); *Scaled Exponential Linear Unit* (SELU); e *Gaussian Error Linear Unit* (GELU). A análise das curvas de aprendizado (Figura 22) revelou que, enquanto as funções saturantes (Sigmoide e Tanh) exigiram mais de 1000 épocas para estabilização, as funções retificadoras (RELU e suas variações) convergiram entre 100 e 160 épocas. Em termos de precisão final (Tabela 13), a RELU e a GELU apresentaram desempenhos estatisticamente semelhantes, com leve superioridade para a primeira. Assim, optou-se pela utilização da RELU, devido sua menor

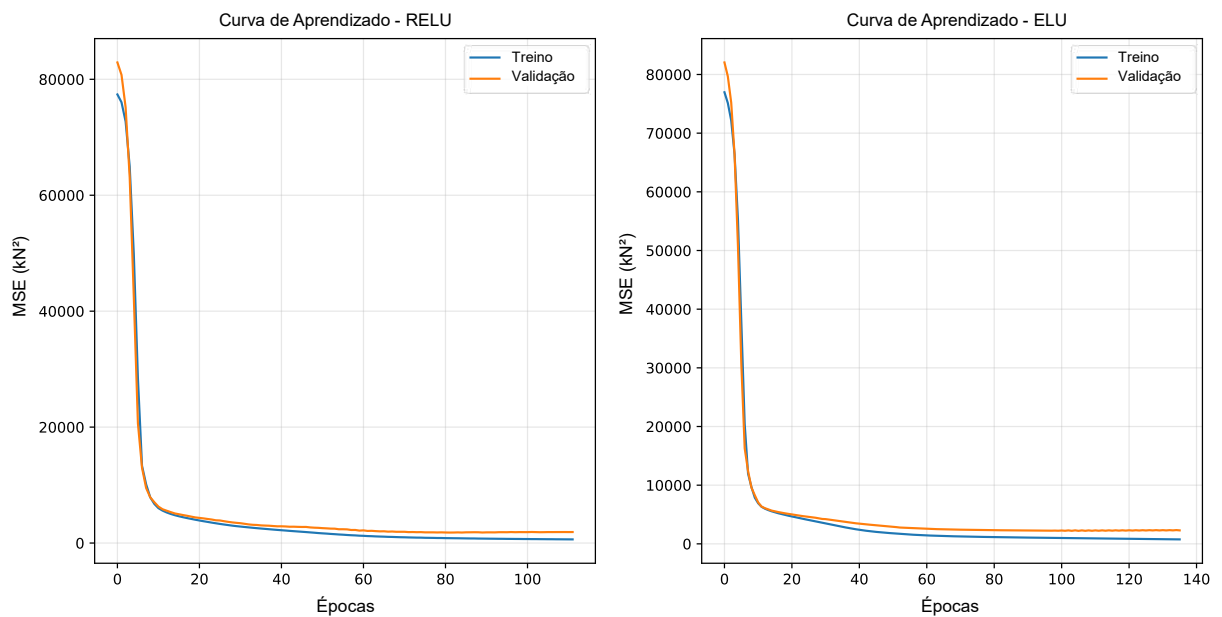
demanda computacional. Destaca-se que essa função de ativação apresentou o melhor ajuste global quando associada ao inicializador de pesos *Xavier Glorot Uniform*.

Tabela 13 - Análise das funções de ativação.

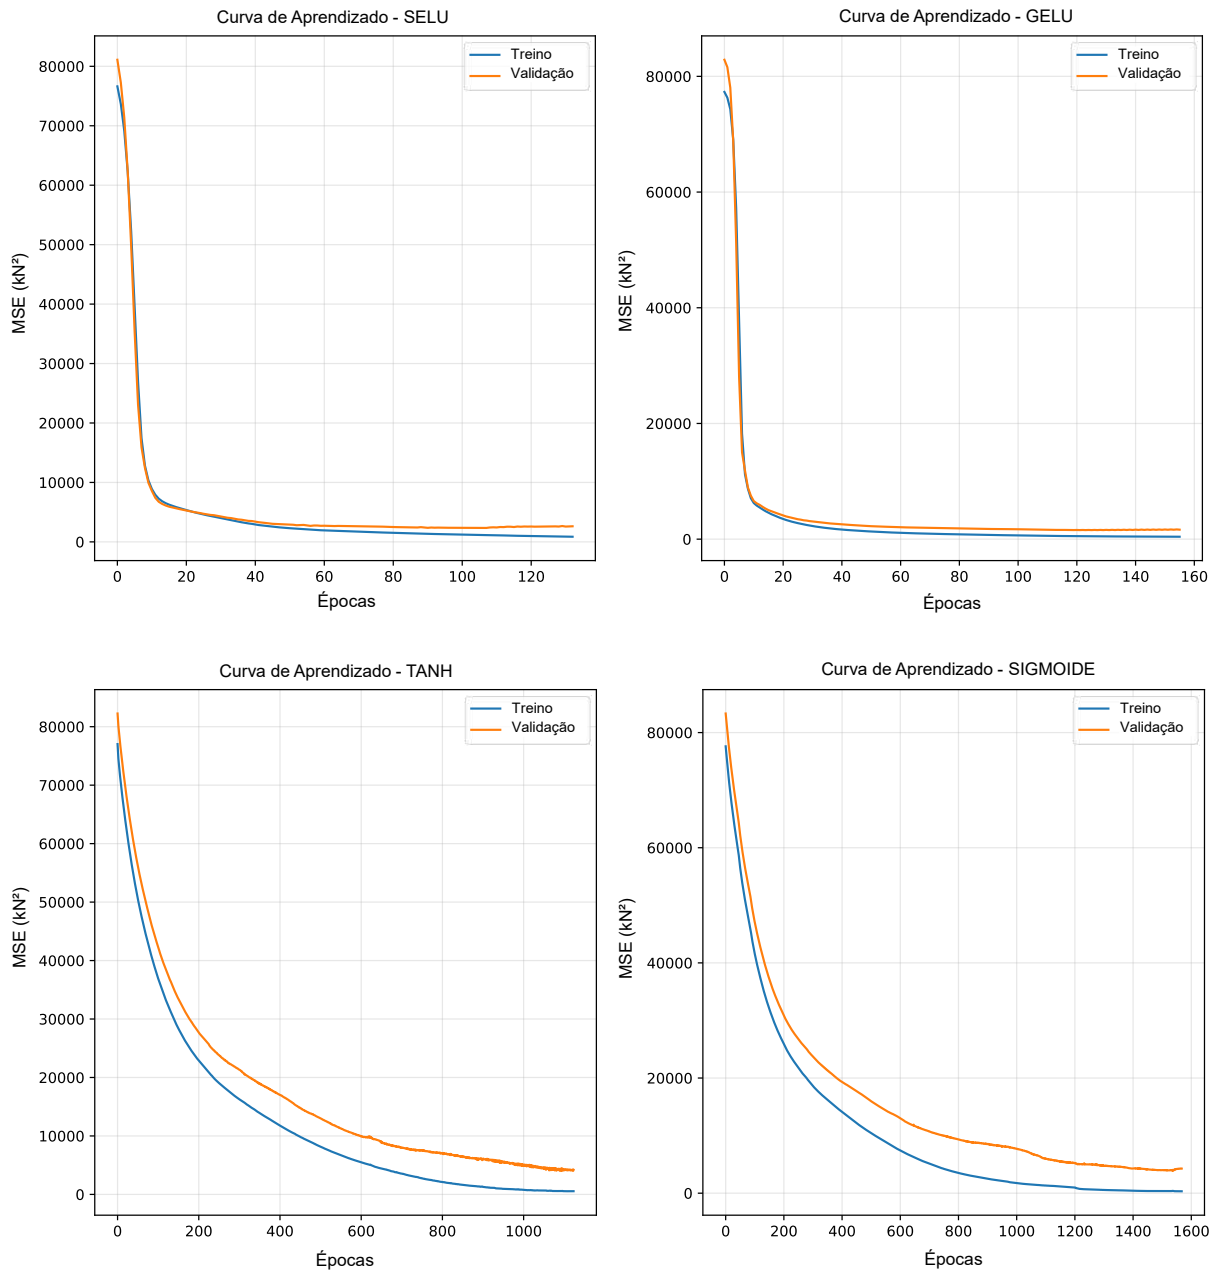
Função de ativação	Validação		Teste cego	
	R ²	RMSE (kN)	R ²	RMSE (kN)
Função sigmoide	0,8688	60,14	0,8743	59,45
TANH	0,7615	79,60	0,7107	90,19
RELU	0,8881	52,25	0,9075	51,00
ELU	0,9023	51,73	0,9056	51,52
SELU	0,8707	59,36	0,8964	53,98
GELU	0,8729	53,83	0,9024	52,39

Fonte: Elaborado pelo autor.

Figura 22 - Curvas de aprendizagem das funções de ativação.



Continuação.



Fonte: Elaborado pelo autor.

Com o objetivo de reduzir o *overfitting*, foram avaliadas técnicas de regularização no modelo base. Inicialmente, o método de *Dropout* foi aplicado para a regularização dos pesos da RNA. A definição da taxa de *Dropout* foi realizada testando-se configurações entre 0% e 40% para avaliar o equilíbrio entre o aprendizado do modelo e sua capacidade de generalização. Os resultados obtidos, apresentados na Tabela 14, indicam que a taxa de 10% proporcionou o melhor desempenho. Embora a configuração de 20% tenha atingido o maior coeficiente de determinação na etapa de validação, ela falhou em manter a consistência no teste cego, onde

seu desempenho sofreu uma degradação considerável. Por outro lado, a taxa de 10% de *Dropout* apresentou a melhor consistência entre as fases, alcançando os menores erros médios globais (RMSE de 45,16 kN na validação e 44,80 kN no teste cego).

A partir da análise visual das curvas de aprendizado (Figura 23), nas taxas de 20% a 40% de *Dropout*, observa-se um distanciamento progressivo e ruidoso entre as curvas, indicando dificuldade de convergência. Um aspecto particular deve ser notado na curva de aprendizado da taxa de 10%: a curva de perda de treinamento exibe um comportamento oscilatório, enquanto a curva de validação comporta-se quase que estável e posicionada abaixo da curva de treino.

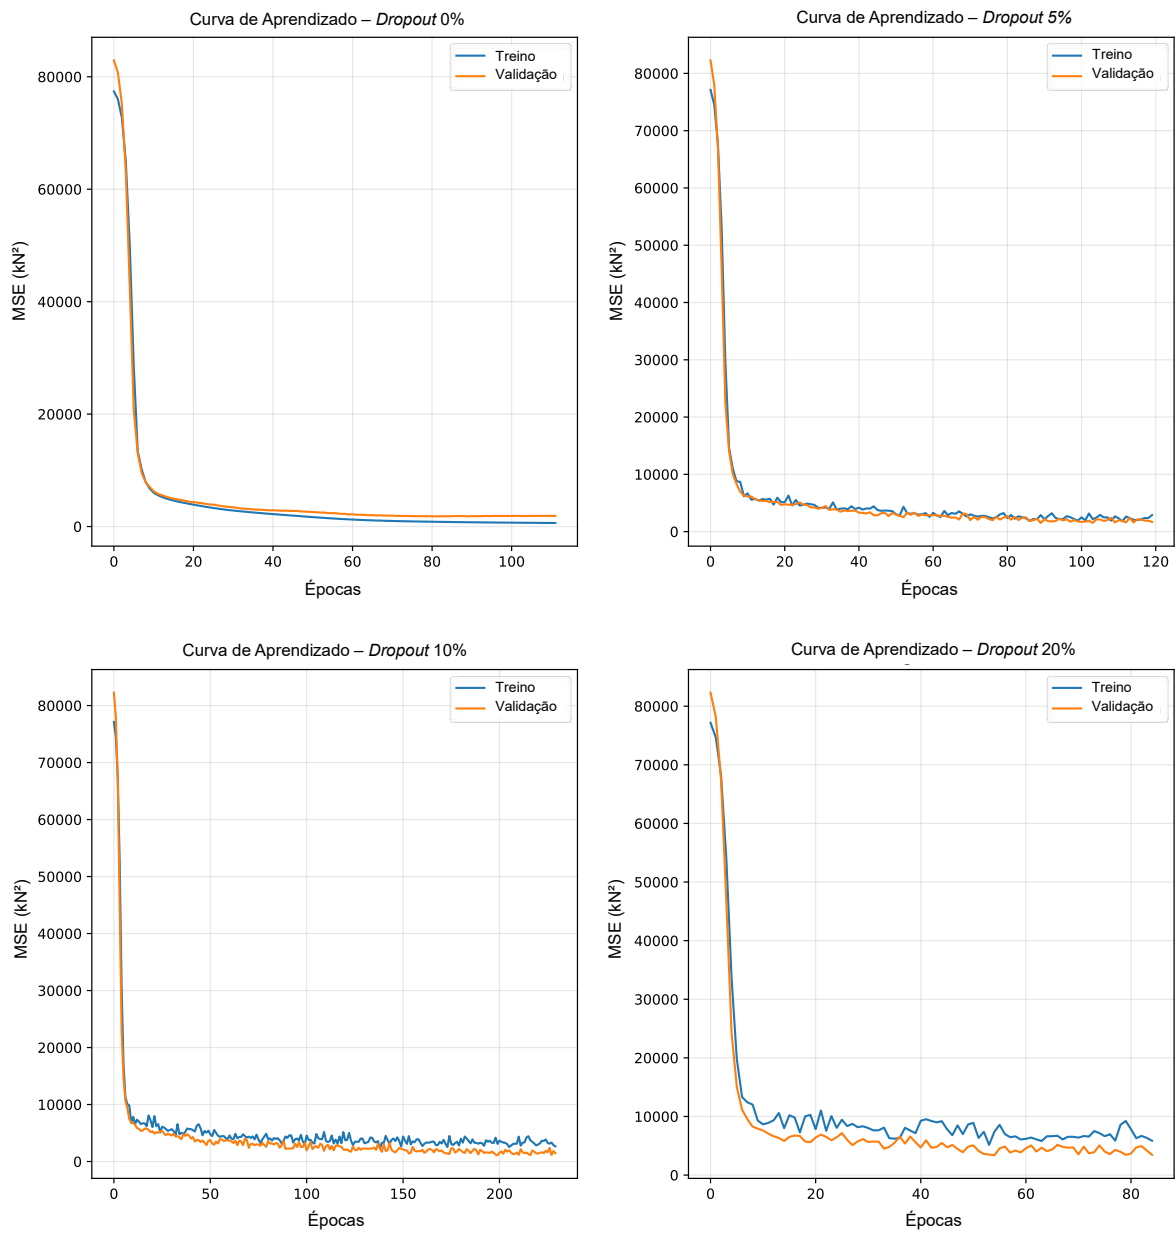
Como o *Dropout* desativa aleatoriamente 10% dos neurônios a cada época, a rede é continuamente forçada a treinar com arquiteturas distintas, o que gera flutuações naturais na métrica de erro. Por outro lado, durante a validação, todos os neurônios são ativados (o *Dropout* é desligado), permitindo que o modelo utilize toda a robustez adquirida "sob estresse". O fato de a curva de validação ser mais suave e apresentar menor erro que a de treino confirma que a rede não apenas aprendeu os padrões, mas desenvolveu redundância interna suficiente para generalizar com precisão.

Tabela 14 - Aplicação do método de *Dropout*.

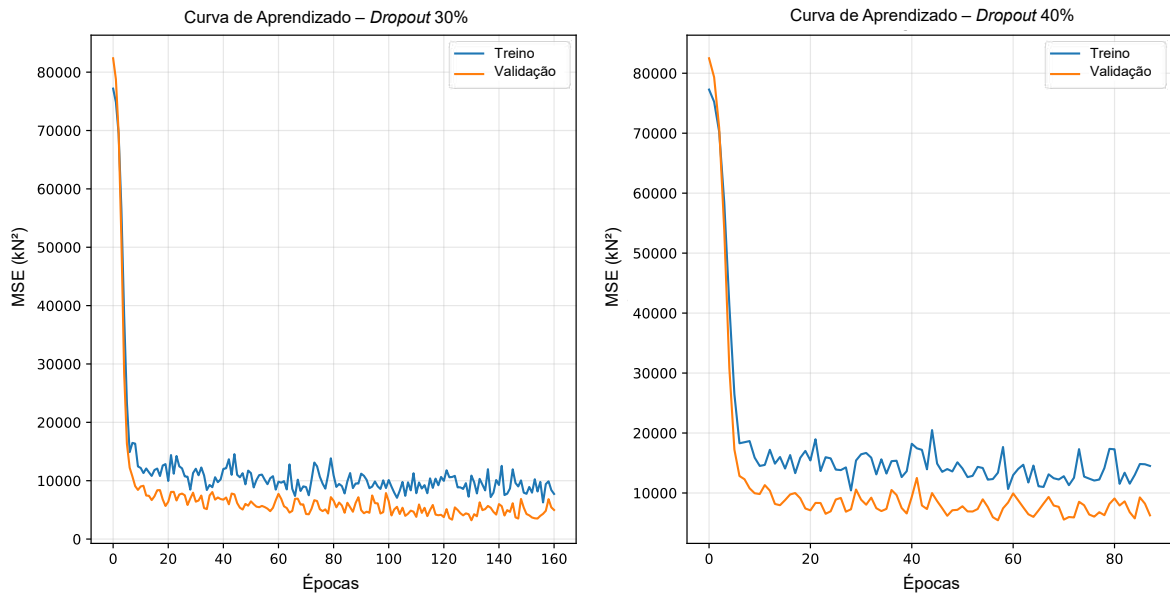
<i>Dropout</i>	Validação		Teste cego	
	R ²	RMSE (kN)	R ²	RMSE (kN)
0%	0,8881	52,25	0,9075	51,00
5%	0,8822	47,88	0,8745	59,39
10%	0,9109	45,16	0,9286	44,80
20%	0,9111	48,61	0,7236	88,15
30%	0,9044	51,67	0,7926	76,35
40%	0,8997	52,12	0,725	87,92

Fonte: Elaborado pelo autor.

Figura 23 - Curvas de aprendizado para Dropout.



Continuação.



Fonte: Elaborado pelo autor.

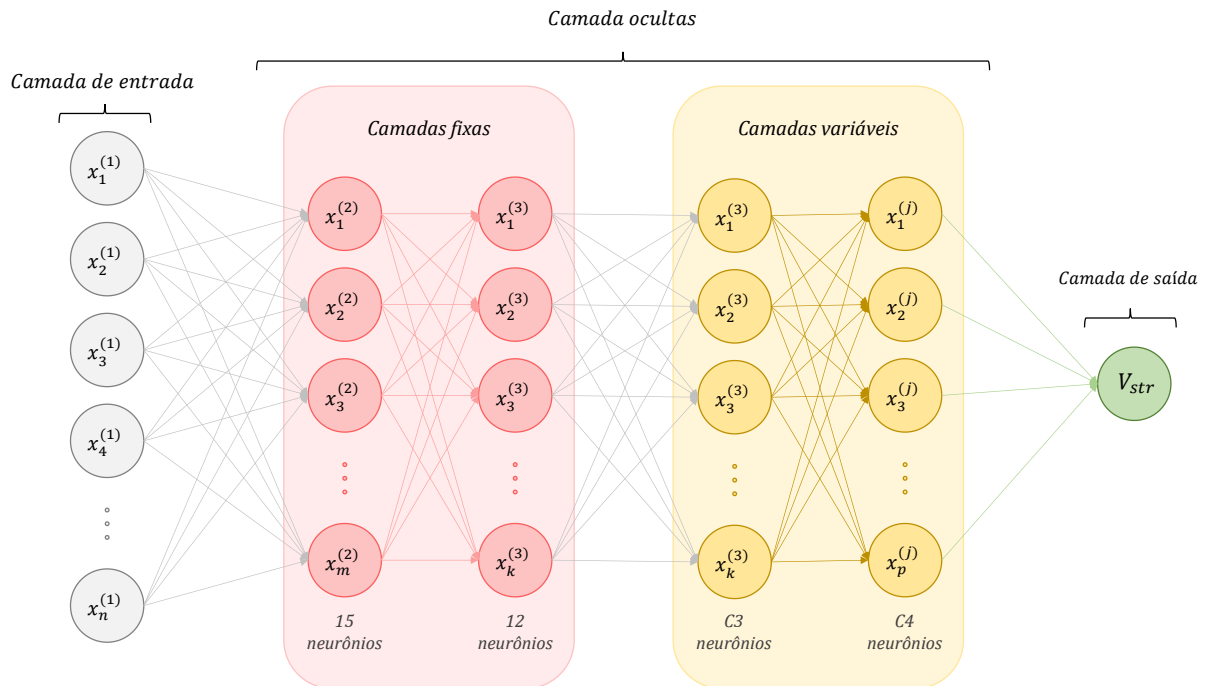
7.2 Otimização da Topologia da Rede Neural

Visando determinar a arquitetura que oferece o melhor equilíbrio entre capacidade de aprendizado e generalização, foi conduzido um estudo paramétrico focado na profundidade da rede neural. A estratégia consistiu em fixar as duas primeiras camadas ocultas do modelo base (contendo 15 e 12 neurônios, respectivamente), e variar sistematicamente a configuração das camadas subsequentes. O número de camadas e de neurônios por camada foram limitados em 4 e 15, respectivamente, devido ao alto custo computacional para arquiteturas mais robustas.

O processo de avaliação seguiu uma abordagem iterativa e hierárquica, dividida em duas etapas distintas: (i) Varredura de Arquiteturas e (ii) Refinamento do Melhor Modelo.

Na fase de varredura, buscou-se identificar a topologia mais eficiente através de um *loop* de testes. Partindo de uma configuração base, as arquiteturas evoluíram pela variação conjunta da terceira (C3) e da quarta (C4) camadas ocultas. O número de neurônios em C3 variou de 1 a 15, enquanto C4 variou de 0 a 15. Assim, testaram-se configurações desde [15, 12, 1, 0] (três camadas ocultas) até [15, 12, 15, 15] (quatro camadas ocultas densas). Para garantir a robustez estatística e evitar que a escolha fosse enviesada por uma divisão de dados favorável, utilizou-se o método de Validação Cruzada. As métricas de desempenho (RMSE e R^2) foram calculadas pela média dos 5 *folds*. A Figura 24 apresenta de forma esquemática a metodologia adotada para avaliar as arquiteturas mais profundas do modelo de RNA.

Figura 24 - Representação esquemática da metodologia utilizada para avaliar a arquitetura da rede.



Fonte: Elaborado pelo autor.

Nesta etapa preliminar, o limitou-se o número de épocas em 200 para garantir que arquiteturas mais profundas tivessem iterações suficientes para propagar o gradiente e iniciar a convergência, garantindo uma competição justa entre redes de diferentes complexidades, além de padronizar o processo e reduzir o custo computacional. Ademais, empregou o *Early Stopping*, com monitoramento da função de perda nos dados de validação, com paciência de 30 épocas e restauração dos melhores pesos. Isso assegura que o modelo final corresponda ao ponto ótimo de generalização, interrompendo o treinamento caso o erro de validação comece a divergir do erro de treinamento assegurando que o treinamento fosse interrompido no ponto ótimo de generalização, mitigando o risco de *overfitting*.

Após a identificação da arquitetura com o menor RMSE na validação cruzada, iniciou-se a fase de treinamento definitivo. A estratégia de treinamento foi alterada para priorizar a máxima performance e evitar o *overfitting*. Nessa etapa, o limite de épocas foi ampliado para 2000, permitindo que o modelo realizasse o ajuste fino dos pesos. Assim como na etapa de varredura, foi utilizado o *Early Stopping* para obtenção do máximo desempenho do modelo.

Por fim, a capacidade preditiva do modelo otimizado foi verificada em um Conjunto de Teste Cego (correspondente a 10% dos dados originais), que foi mantido isolado e não

participou de nenhuma etapa de treinamento ou seleção de arquitetura, garantindo assim uma avaliação imparcial do desempenho real da rede neural frente a novos dados experimentais.

A Tabela 15 apresenta o *heatmap* dos coeficientes de determinação médios obtidos na validação cruzada nos testes das arquiteturas das redes. A análise dos resultados permite identificar quatro comportamentos distintos que caracterizam a resposta do modelo à complexidade da arquitetura. Inicialmente, observa-se uma degradação severa de desempenho nas regiões onde a profundidade da rede aumenta sem a devida largura (número de neurônios reduzido nas camadas C3 e C4, entre 1 e 4 neurônios).

Tal fenômeno ocorre devido à combinação de dois fatores. O primeiro é o gargalo de informação: ao forçar os dados a passarem por camadas excessivamente estreitas, há uma perda de representatividade do fenômeno. Além disso, há a probabilidade elevada da ocorrência de neurônios mortos ao utilizar a ativação RELU em arquiteturas reduzidas. Se os poucos neurônios disponíveis saturarem em zero, a transmissão de informação é cessada. O resultado é um modelo estagnado, incapaz de convergir (visto que os pesos não se justam) e com desempenho inferior à média dos dados observados.

A primeira linha da matriz ($C4 = 0$) representa as topologias com apenas três camadas ocultas. Nota-se uma estabilidade consistente nesta configuração, com o R^2 variando marginalmente entre 0,81 e 0,87. Isso sugere que uma rede de três camadas possui robustez suficiente para modelar o problema com boa acurácia, servindo como uma linha de base segura.

Por outro lado, foram identificados pontos isolados de baixa performance em regiões adjacentes a bons resultados, como em $C3=12$ e $C4=1$ (0,39); e para $C3=7$ e $C4=13$ (0,15). Essas anomalias evidenciam a natureza estocástica do treinamento de redes neurais. Mesmo em arquiteturas viáveis, a inicialização aleatória dos pesos, combinada com a complexidade da superfície de erro, pode ocasionalmente prender o otimizador em mínimos locais inadequados durante um ou mais *folds* da validação cruzada, penalizando a média final.

O pico de desempenho preditivo foi alcançado na configuração com 12 neurônios na terceira camada e 7 na quarta camada, atingindo um R^2 médio de 0,89. Esta arquitetura superou o limite de 0,87 observado nas redes de três camadas, demonstrando que o aprofundamento da rede (adição da quarta camada), quando acompanhado de uma largura adequada, permitiu ao modelo capturar nuances não-lineares mais complexas do comportamento das vigas reforçadas com CFRP.

Tabela 15 - Análise de Sensibilidade da Topologia das Camadas Profundas.

C3	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
C4	R2 Médio (k = 5 folds)														
0	0.83	0.84	0.83	0.81	0.86	0.83	0.84	0.87	0.85	0.84	0.83	0.86	0.85	0.86	0.85
1	-1.57	-1.57	-1.57	-1.57	0.82	0.85	0.85	-1.57	0.85	0.84	0.86	0.39	0.83	0.85	0.87
2	-1.57	-1.57	0.84	0.85	0.85	0.84	0.86	0.87	0.84	0.85	0.85	0.86	0.83	0.86	0.85
3	-1.57	-1.57	-1.57	0.85	0.83	0.86	0.85	0.82	0.85	0.86	0.84	0.87	0.85	0.87	0.86
4	-1.57	0.85	0.84	0.85	0.86	0.85	0.86	0.87	0.88	0.83	0.85	0.84	0.87	0.85	0.86
5	0.84	0.83	0.84	0.84	0.85	0.85	0.87	0.86	0.86	0.87	0.84	0.88	0.87	0.86	0.87
6	0.85	0.83	0.85	0.86	0.87	0.86	0.86	0.87	0.86	0.85	0.85	0.86	0.86	0.87	0.86
7	0.84	0.85	0.85	0.84	0.85	0.86	0.84	0.87	0.85	0.86	0.84	0.89	0.84	0.85	0.85
8	0.84	0.84	0.85	0.85	0.85	0.84	0.87	0.86	0.87	0.87	0.87	0.88	0.86	0.85	0.86
9	0.84	0.83	0.84	0.86	0.84	0.88	0.87	0.86	0.82	0.87	0.86	0.86	0.86	0.87	0.87
10	0.84	0.85	0.86	0.86	0.86	0.84	0.86	0.86	0.88	0.88	0.83	0.86	0.83	0.86	0.87
11	0.84	0.82	0.85	0.86	0.84	0.87	0.85	0.86	0.87	0.84	0.86	0.87	0.86	0.86	0.86
12	0.85	0.86	0.85	0.85	0.86	0.85	0.86	0.85	0.88	0.85	0.85	0.87	0.88	0.84	0.85
13	0.85	0.84	0.84	0.85	0.84	0.85	0.15	0.87	0.88	0.84	0.86	0.86	0.86	0.87	0.86
14	0.85	0.85	0.85	0.85	0.85	0.85	0.86	0.88	0.87	0.84	0.86	0.81	0.85	0.85	0.87
15	0.86	0.40	0.85	0.85	0.87	0.86	0.87	0.83	0.85	0.84	0.88	0.87	0.85	0.88	0.87

Fonte: Elaborado pelo autor.

7.3 Análise de sensibilidade com regularização L1

Após a etapa preliminar de seleção de variáveis baseada em análises estatísticas (correlações de Pearson e Spearman), procedeu-se ao treinamento das Redes Neurais Artificiais. Embora a filtragem inicial tenha removido variáveis linearmente irrelevantes, a alta dimensionalidade restante e a natureza não-linear do problema de cisalhamento em vigas reforçadas com FRP exigiram uma camada adicional de controle de complexidade para evitar o *overfitting*. Para isso, aplicou-se a técnica de Regularização L1 (LASSO), variando-se o hiperparâmetro de penalidade (λ) nos valores de 0,1, 0,01, 0,001 e 0,0001. O objetivo foi avaliar a capacidade do modelo em lidar com a multicolinearidade residual não-linear e garantir a generalização em dados desconhecidos.

7.3.1 Regularização L1 (LASSO) com variáveis selecionadas

A Tabela 16 apresenta o desempenho dos modelos sob diferentes penalidades. Observou-se um comportamento não-monotônico no erro, evidenciando a existência de um ponto ótimo de regularização. O modelo configurado com penalidade de 0,01 demonstrou desempenho superior aos demais. Obteve-se o menor erro no teste cego (29,64 kN), bem como alta consistência entre os coeficientes de determinação de validação (0,9185) e teste (0,9239), indicando um modelo robusto e com excelente capacidade de generalização.

Tabela 16 - Regularização L1 aplicado às variáveis selecionadas.

Penalidade LASSO	Validação		Teste cego	
	R ²	RMSE	R ²	RMSE
0,1	0,7882	58,01	0,9348	40,30
0,01	0,9185	48,44	0,9239	29,64
0,001	0,9037	49,65	0,9025	49,29
0,0001	0,8881	52,25	0,9075	51,00

Fonte: Elaborado pelo autor.


Por outro lado, a aplicação de uma penalidade maior (0,1) resultou em uma degradação do aprendizado durante a validação cruzada (R² de 0,7882), caracterizando *underfitting*. Embora o R² no teste cego tenha sido elevado (0,9348), o erro absoluto (40,30 kN) foi significativamente maior que o do modelo otimizado, sugerindo que a rede foi impedida de ajustar os pesos para capturar a precisão necessária.

Os modelos com penalidades baixas (0,001 e 0,0001), apesar de a seleção prévia via Pearson/Spearman ter sido realizada, apresentaram erros elevados no teste cego (RMSE médio de 50,14 kN). Este comportamento sugere que a filtragem estatística linear foi insuficiente para eliminar redundâncias complexas (não-lineares) entre as variáveis de entrada. A influência reduzida da regularização L1 para zerar ou reduzir pesos de variáveis redundantes fez com que a rede neural inflasse a importância de ruídos estatísticos, prejudicando a precisão final das previsões.

A aplicação da Regularização L1 atuou como um refinamento essencial pós-seleção estatística. O hiperparâmetro $\lambda = 0,01$ foi adotado para o modelo final devido sua maior capacidade de mitigar a multicolinearidade residual que os métodos de correlação linear não detectaram, reduzindo o erro de predição em aproximadamente 41,88% quando comparado aos

modelos pouco regularizados. A Figura 25 apresenta os pesos dos neurônios da camada de entrada do modelo de RNA.

Figura 25 - Pesos da camada de entrada para modelo com variáveis selecionadas e $\lambda = 0,01$.



Fonte: Elaborado pelo autor.

Após a aplicação da Regularização L1, todas as variáveis de entrada foram mantidas ativas pelo modelo. Este comportamento indica que a etapa preliminar de seleção de variáveis, baseada nas correlações de Pearson e Spearman, foi eficaz em remover atributos irrelevantes. Nesse caso, o ganho de desempenho observado deve-se, portanto, ao efeito de contração de parâmetros.

A regularização atuou limitando a magnitude dos pesos sinápticos, prevenindo que a rede neural explorasse compensações numéricas excessivas entre variáveis correlacionadas (multicolinearidade). Como resultado, o modelo convergiu para uma solução onde a hierarquia de importância das variáveis reflete a física do problema: a altura útil apresentou a maior preponderância, seguida pelas características geométricas da viga e do reforço.

Sob outra perspectiva, um padrão particular é observado no comportamento das variáveis binárias referentes à presença de armadura transversal. A análise dos pesos revela que

a distinção categórica entre vigas com e sem estribos tornou-se irrelevante para a rede neural. A proximidade dos valores (aproximadamente 10,00 e 10,18) indica que essas variáveis geram sinais de saída quase idênticos, independentemente da categoria. Isso sugere que a codificação One-hot gerou redundância: como as variáveis são mutuamente exclusivas, a rede as interpretou como um viés quase constante. Esse fenômeno demonstra que o modelo aprendeu que a simples presença de estribos é menos informativa do que suas propriedades físicas, priorizando as variáveis quantitativas associadas ao cisalhamento, especificamente a taxa de armadura transversal (ρ_s) e a tensão de escoamento ($f_{sy,s}$), em detrimento da classificação binária.

Fisicamente, isso demonstra que o modelo capturou corretamente que a contribuição dos estribos para a resistência ao cisalhamento é uma função contínua da taxa de armadura transversal, e não um simples incremento baseado apenas na existência de estribos. As variáveis categóricas, neste caso, atuaram apenas como um valor de viés (bias) estrutural para garantir a ativação dos neurônios, transferindo a responsabilidade preditiva para os parâmetros numéricos mais significativos.

7.3.2 Regularização L1 (LASSO) com todas as variáveis

Para validar a eficácia da etapa de pré-processamento baseada em correlações (Pearson/Spearman), realizou-se um segundo experimento utilizando o conjunto completo de variáveis disponíveis, delegando inteiramente ao algoritmo LASSO a tarefa de seleção e ponderação de atributos.

Ao observar os resultados para o RMSE da Tabela 17, constata-se que a inserção de variáveis não filtradas degradou severamente a capacidade preditiva do modelo. Enquanto o modelo com pré-seleção estatística alcançou um RMSE ótimo de 29,64 kN ($\lambda = 0,01$), o melhor desempenho obtido no cenário com todas as variáveis foi de 42,26 kN (exigindo uma penalidade mais agressiva de $\lambda = 0,1$). Isso representa um aumento de aproximadamente 42,59% no erro de predição.

Os pesos dos neurônios da camada de entrada para o modelo com todas as variáveis e regularização com $\lambda = 0,1$ são apresentados na Figura 26. No modelo pré-filtrado, a altura útil (d) foi identificada como preditor dominante (peso de 20,60). Contudo, no modelo sem filtro, a introdução da altura total (h), uma variável altamente correlacionada com d , causou um efeito de diluição no ajuste. O algoritmo distribuiu a importância entre h (peso de 12,21) e d (peso de

7,34), além de atribuir pesos elevados a variáveis geométricas secundárias, impedindo que o modelo convergisse para a solução ótima.

Tabela 17 - Regularização L1 aplicado à todas as variáveis.


Penalidade LASSO	Validação		Teste cego	
	R ²	RMSE	R ²	RMSE
0,1	0,9245	46,70	0,9470	42,26
0,01	0,9170	50,38	0,9318	47,94
0,001	0,9203	50,30	0,9295	48,72
0,0001	0,9022	54,74	0,9143	53,74

Fonte: Elaborado pelo autor.

A presença de estribos nas vigas apresentou um comportamento particular. Enquanto no modelo otimizado pelo tratamento estatístico preliminar os pesos relativos às categorias com estribos e sem estribos se anulavam mutuamente (apresentando uma diferença de 0,18), indicando que a predição dependia puramente da taxa quantitativa de armadura, no modelo sem pré-seleção observou-se um distanciamento significativo entre esses coeficientes. Neste cenário, a variável relativa à presença de estribos recebeu um peso de 9,15, enquanto a relativa à ausência apresentou um peso de 7,58, criando um viés aditivo de 1,57 para vigas com armadura transversal.

Fisicamente, isso sugere que o modelo, prejudicado pela diluição de sinal causada por variáveis redundantes, não conseguiu capturar plenamente a relação entre a taxa de armadura transversal e a resistência ao cisalhamento. Como compensação matemática, a rede recorreu à variável categórica para aplicar um incremento fixo de resistência baseado na simples presença do reforço, comportando-se como uma função degrau. Tal comportamento evidencia uma perda de refinamento físico em comparação ao modelo híbrido, que conseguiu generalizar a contribuição do aço de forma mais efetiva.

Figura 26 - Pesos da camada de entrada para modelo com todas as variáveis e regularização com $\lambda = 0,1$.



* Variáveis que foram adicionadas para análise completa.

Fonte: Elaborado pelo autor.

7.4 Discussão dos resultados obtidos via RNA

Este capítulo teve como objetivo descrever o estudo realizado para o desenvolvimento e a otimização de modelos de Redes Neurais Artificiais (RNA) capazes de prever, com alta precisão, a resistência ao cisalhamento total de vigas de concreto armado reforçadas com EB-FRP. O estudo buscou superar as limitações das formulações normativas analisadas, que apresentam alta variabilidade nos resultados e baixa correlação com dados experimentais.

A metodologia adotada baseou-se na otimização dos hiperparâmetros e topologia da RNA por meio da análise de diversos modelos parametrizados. Inicialmente, avaliou-se a eficiência de diferentes algoritmos de otimização, taxas de aprendizado e funções de ativação. Posteriormente, realizou-se um estudo paramétrico na profundidade da rede, testando-se arquiteturas com até quatro camadas ocultas. Para garantir a capacidade de generalização e evitar o *overfitting*, foram aplicadas técnicas de regularização (*Dropout* e LASSO) e validou-

se o modelo através de um processo de validação cruzada ($k = 5 \text{ folds}$), com verificação final em um conjunto de teste cego isolado.

Os resultados obtidos demonstraram que os hiperparâmetros que, em seus respectivos testes, proporcionaram o melhor equilíbrio entre velocidade de convergência e precisão foram: o otimizador Adam; a taxa de aprendizado de 0,001; e a função de ativação RELU. Por outro lado, a arquitetura profunda contendo quatro camadas ocultas, com a configuração de neurônios [15, 12, 12, 7], atingiu o pico de desempenho preditivo, superando as redes mais rasas e demonstrando a capacidade de capturar as não-linearidades complexas do comportamento do FRP.

Na análise de estratégias para mitigar a ocorrência de *overfitting*, a regularização L1 aplicada a variáveis pré-selecionadas (com penalidade de 0,01) mostrou-se superior ao método de *Dropout* (com taxa de 10%), que causou instabilidade no treinamento. Além disso, a análise dos pesos sinápticos revelou que a RNA foi capaz de filtrar a multicolinearidade e interpretar corretamente a física do problema. O modelo atribuiu importância nula ao viés categórico da presença de estribos, priorizando a variável quantitativa da taxa de armadura transversal, o que confirma a robustez e a coerência da solução proposta.

É importante destacar que os hiperparâmetros de uma Rede Neural Artificial possuem interdependências complexas, onde a alteração de um fator pode influenciar a eficácia de outro, como, por exemplo, a relação direta entre a taxa de aprendizado e o tipo de otimizador. Ciente dessa complexidade e das limitações computacionais para uma busca exaustiva combinatória, esta pesquisa adotou uma abordagem de otimização independente. A metodologia consistiu em avaliar o desempenho de cada hiperparâmetro (otimizadores, funções de ativação, taxa de aprendizado, *Dropout* e LASSO) de forma isolada em relação a um modelo base. O modelo final foi, portanto, constituído pela combinação das configurações que obtiveram os melhores resultados individuais em suas respectivas categorias, não sendo objeto deste estudo a análise das interações cruzadas entre esses parâmetros.

As relações de interdependência entre os hiperparâmetros torna-se evidente na análise da Tabela 18, que apresenta os resultados da combinação simultânea das configurações vencedoras dos testes individuais. Ao aplicar esses parâmetros às arquiteturas base [15, 12] e profunda [15, 12, 12, 7], observou-se que a simples agregação de características ótimas individuais não resultou no melhor modelo global. Pelo contrário, notou-se uma acentuada perda de capacidade de generalização: enquanto o R^2 de validação atingiu valores altos (0,9320), o desempenho no teste cego caiu drasticamente para a ordem de 0,83. Essa

discrepância confirma que a otimização isolada ignora os efeitos de acoplamento entre as variáveis, levando a um modelo final instável e propenso ao *overfitting*.

Tabela 18 - Modelos com os melhores hiperparâmetros.

Arquitetura	Validação		Teste cego	
	R ²	RMSE	R ²	RMSE
[15, 12]	0,9320	45,28	0,8396	73,52
[15, 12, 12, 7]	0,903	55,08	0,8331	74,99

Fonte: Elaborado pelo autor.

Após a análise de 270 modelos de RNA, a arquitetura base associada à técnica de Regularização LASSO destacou-se com a melhor performance (detalhes dos hiperparâmetros na Tabela 19). A superioridade desse modelo fica evidente na predição da resistência ao cisalhamento (Figura 27): enquanto a RNA alcançou um coeficiente de determinação de 0,9593, as normativas internacionais apresentaram correlações significativamente inferiores. A norma ACI 440.2R-17 obteve R² de 0,5199, seguida pela fib Bulletin 14 com 0,2785 e pela fib Bulletin 90 com apenas 0,2625.

Os desvios-padrão obtidos pelas ACI 440.2R-17, FIB BULLETIN 14, (2001) e a fib Bulletin 90 (2019) foram de 139,76, 205,22 e 612,72, respectivamente. Por outro lado, o modelo de RNA apresentou desvio-padrão de 178,33, representando uma redução de aproximadamente 44,20% em relação à média das normas internacionais. Embora esse valor seja superior ao do modelo M11 (obtido via regressão linear múltipla), ao se analisar o MAE, a RNA obteve valores 74,98%, 79,74% e 89,33% menores do que as referidas normas, além de 67,69% menor do que o erro do modelo M11. Isso indica que a RNA modelou de forma mais eficiente o comportamento do fenômeno e suas não-linearidades.

Tabela 19 - Modelo de RNA com melhor desempenho.

Arquitetura	[15, 12]	
Otimizador	Adam	
Taxa de aprendizado	0,01	
Função de ativação	RELU	
Dropout	0%	
Regularização LASSO	0,01	
Validação (5 folds)	R ²	0,9185
	RMSE	48,44
Teste cego	R ²	0,9239
	RMSE	29,64

Fonte: Elaborado pelo autor.

Figura 27 - Predição de resistência com base nas normativas internacionais e modelo de RNA.



Fonte: Elaborado pelo autor.

8 CONCLUSÃO

O presente trabalho dedicou-se à construção de um banco de dados de vigas de concreto armado reforçadas ao cisalhamento com EB-FRP. A partir desse conjunto, procedeu-se uma análise das principais abordagens normativas existentes para a prescrição da resistência ao cisalhamento desses elementos, bem como o desenvolvimento e validação de modelos preditivos. A pesquisa estruturou-se em duas frentes complementares: a análise estatística via Regressão Linear Múltipla e a modelagem não linear via Redes Neurais Artificiais (RNA), ambas fundamentadas em um extenso banco de dados consolidado com 524 vigas experimentais provenientes de 82 estudos distintos.

A etapa inicial de análise de sensibilidade e correlação permitiu reduzir a dimensionalidade do problema, identificando as 17 variáveis de maior relevância estatística. Um achado crítico desta fase foi a constatação de que as normas vigentes negligenciam a influência da armadura longitudinal interna. As análises comprovaram que essa variável é determinante para a resistência ao cisalhamento, sendo essencial sua inclusão nos modelos preditivos propostos.

Com base nesses parâmetros, foram desenvolvidos modelos de Regressão Linear Múltipla. Destacou-se o modelo M11, obtido após a aplicação da técnica de eliminação *Backward*, em que a dimensionalidade do problema foi reduzida para 11 variáveis. Este modelo apresentou um equilíbrio notável entre simplicidade e precisão (com R^2 de 0,74), superando as formulações normativas e validando a viabilidade de equações lineares para estimativas iniciais, embora apresente maior desvio para cargas superiores a 400 kN devido à escassez de dados experimentais nesta faixa de resistência.

Visando modelar as não-linearidades do comportamento do reforço ao cisalhamento com EB-FRP, a pesquisa aplicou Redes Neurais Artificiais (RNA), cuja otimização de hiperparâmetros e topologia resultou em modelos com capacidade preditiva significativamente superior às metodologias normativas. Dentre as configurações analisadas, a que utilizou a Regularização L1 (LASSO) obteve o melhor desempenho, com coeficiente de determinação na ordem de 0,90, superando o *Dropout* na prevenção do *overfitting* e garantindo maior generalização. Contudo, o modelo com Regularização L1 com variáveis selecionadas apresentou o melhor desempenho, com métricas de validação e testes coerentes, e R^2 e RMSE médios de 0,92 e 29,64kN, respectivamente.

Além da superioridade estatística (evidenciada por maiores coeficientes de determinação, menor dispersão e MAE em comparação às normas e ao modelo de regressão linear), a RNA demonstrou consistência física. A análise dos pesos sinápticos revelou que o modelo anulou corretamente a influência da variável categórica redundante “presença de estribos”, priorizando a variável quantitativa da taxa de armadura transversal. Dessa forma, a redução da dimensionalidade aliada às RNA demonstrou-se ser a abordagem mais eficiente para a predição da resistência ao cisalhamento nesses elementos.

Em suma, esta pesquisa viabilizou a construção de um robusto banco de dados experimental, abrangendo diversos cenários de reforço estrutural com EB-FRP. Este repositório constitui uma contribuição relevante para investigações futuras sobre o fenômeno do cisalhamento nesses elementos. Ademais, a análise de sensibilidade permitiu a redução da dimensionalidade do problema, simplificando a modelagem das relações complexas entre os parâmetros que governam o comportamento das vigas reforçadas com o material compósito.

No que tange aos modelos desenvolvidos, o modelo linear M11 superou significativamente a precisão das normativas internacionais, fornecendo uma formulação prática e de fácil aplicação em projetos de engenharia. Paralelamente, a implementação da Rede Neural Artificial estabeleceu um elevado patamar de precisão, consolidando-se como uma ferramenta robusta para o dimensionamento estrutural contemporâneo. Embora o processo de calibração de modelos de aprendizado de máquina exija um esforço computacional exaustivo, a otimização de hiperparâmetros realizada mostrou-se fundamental para maximizar o desempenho preditivo e a capacidade de generalização. Essa rigorosa abordagem metodológica diferencia este trabalho das pesquisas correntes na área, estabelecendo um novo critério de excelência para a aplicação de inteligência artificial na engenharia de estruturas.

8.1 Sugestões de trabalhos futuros

Para trabalhos futuros, sugere-se:

- A utilização de um banco de dados mais amplo e que abrange um maior número de cenários de reforço estrutural com EB-FRP, sobretudo para elementos com faixas de resistência superiores a 400kN;
- Utilizar o modelo de RNA proposto em uma análise de confiabilidade para obtenção de formulações de projeto ou ajuste das formulações normativas existentes;

- Explorar outros algoritmos de aprendizado de máquina, como florestas aleatórias e SVM, para seleção de variáveis e predição da resistência ao cisalhamento total dos elementos.

REFERÊNCIAS

- ABDEL-JABER, Mu'tasim *et al.* Shear strengthening and rehabilitation of high-strength continuous RC beams with BFRP: A combined experimental and numerical study. **Hybrid Advances** v. 12, p. 100592, 1 mar. 2026. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2773207X25002167>. Acesso em: 7 jan. 2026.
- ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 6118: Versão Corrigida 2:2024: Projeto de estruturas de concreto. p. 1–242, 2024. Disponível em: <https://www.normas.com.br/visualizar/abnt-nbr-nm/5211/abnt-nbr6118-projeto-de-estruturas-de-concreto>. Acesso em: 20 ago. 2025.978-85-07-09632-0.
- ABUODEH, Omar R; ABDALLA, Jamal A; HAWILEH, Rami A. Prediction of shear strength and behavior of RC beams strengthened with externally bonded FRP sheets using machine learning techniques. **Composite Structures** v. 234, p. 111698, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822319331423>.
- ACI. **ACI 318M-19: Building Code Requirements for Structural Concrete.**, nº ACI 318M-19. Estados Unidos da América: [s.n.], 2019.
- ACI, 440.2R-17. **Guide for the design and construction of externally bonded FRP systems for strengthening concrete structures.** [S.l.]: American Concrete Institute, 2017. 110 p. “ACI 440.2R-17.” “May 2017.”9781945487590.
- AKKAYA, H C; AYDEMIR, C; ARSLAN, G. Evaluation of shear behavior of short-span reinforced concrete deep beams strengthened with fiber reinforced polymer strips. **ENGINEERING STRUCTURES** v. 299, 2024.
- ALI, Ahmed H. *et al.* Evaluating the shear design equations of FRP-reinforced concrete beams without shear reinforcement. **Engineering Structures** v. 235, p. 112017, 15 maio 2021. Acesso em: 19 fev. 2025.
- BALÁZS, György *et al.* fib Bulletin 90. Externally applied FRP reinforcement for concrete structures. fib Bulletins., maio 2019. Disponível em: https://www.researchgate.net/publication/336579252_fib_Bulletin_90_Externally_applied_FRP_reinforcement_for_concrete_structures. Acesso em: 5 jan. 2025.9782883941328.
- BEN CHAABENE, Wassim; FLAH, Majdi; NEHDI, Moncef L. Machine learning prediction of mechanical properties of concrete: Critical review. **Construction and Building Materials** v. 260, p. 119889, 10 nov. 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950061820318948?via%3Dihub>. Acesso em: 25 jan. 2026.
- BUKHARI, Imran A. *et al.* Shear Strengthening of Short Span Reinforced Concrete Beams with CFRP Sheets. **Arabian Journal for Science and Engineering** v. 38, n. 3, p. 523–536, 1 mar. 2013. Disponível em: <https://link.springer.com/article/10.1007/s13369-012-0333-z>. Acesso em: 8 maio 2024.

CALOFIR, Vasile *et al.* Machine learning-based estimation of seismic structural damage via an accessible web application. **Alexandria Engineering Journal** v. 127, p. 848–862, 1 ago. 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1110016825008063>. Acesso em: 25 jan. 2026.

CHEN, G. M.; TENG, J. G.; CHEN, J. F. Shear Strength Model for FRP-Strengthened RC Beams with Adverse FRP-Steel Interaction. **Journal of Composites for Construction** v. 17, n. 1, p. 50–66, fev. 2013a. Acesso em: 21 maio 2024.

CHEN, G. M.; TENG, J. G.; CHEN, J. F. Shear strength model for FRP-strengthened RC beams with adverse FRP-steel interaction. **Journal of Composites for Construction** v. 17, n. 1, p. 50–66, 1 fev. 2013b. Acesso em: 9 maio 2024.

CHEN, J. F.; TENG, J. G. Shear capacity of FRP-strengthened RC beams: FRP debonding. **Construction and Building Materials** v. 17, n. 1, p. 27–41, 1 fev. 2003. Acesso em: 9 maio 2024.

CHOI, Kyoung Kyu; KIM, Jong Chan; PARK, Hong Gun. Shear Strength Model of Concrete Beams Based on Compression Zone Failure Mechanism. **Structural Journal** v. 113, n. 5, p. 1095–1106, 1 set. 2016. Acesso em: 19 fev. 2025.

CHOI, Kyoung-Kyu *et al.* Maximum Shear Strength of Slender RC Beams with Rectangular Cross Sections. **Journal of Structural Engineering** v. 141, n. 7, p. 04014184, 20 ago. 2014. Disponível em: <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%29ST.1943-541X.0001156>. Acesso em: 19 fev. 2025.

CHOLLET, François; WATSON, Matthew. **Deep Learning with Python**. Third Edition ed. New York, USA: MANNING, 2025. 650 p. Disponível em: <https://deeplearningwithpython.io/>. Acesso em: 5 jan. 2026..9781633436589.

CSA GROUP. **CSA S806:12 (R2021) - Design and construction of building structures with fibre-reinforced polymers**. [S.l.: s.n.], 2012.

D'ANTINO, Tomasso; TRIANTAFILLOU, Thanasis C. Accuracy of design-oriented formulations for evaluating the flexural and shear capacities of FRP-strengthened RC beams. **Structural Concrete** v. 17, n. 3, p. 425–442, 1 set. 2016. Acesso em: 8 maio 2024.

DARKO, Amos *et al.* Artificial intelligence in the AEC industry: Scientometric analysis and visualization of research activities. **Automation in Construction** v. 112, p. 103081, 1 abr. 2020. Acesso em: 3 fev. 2025.

DE IULIIS, M.; MICELI, E.; CASTALDO, P. Machine learning modelling of structural response for different seismic signal characteristics: A parametric analysis. **Applied Soft Computing** v. 164, p. 112026, 1 out. 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494624008007>. Acesso em: 25 jan. 2026.

DEVORE, Jay L. **Probabilidade e Estatística para Engenharia e Ciências**. São Paulo, Brasil: Cengage Learning, 2006. Disponível em: www.cengage.com.br. Acesso em: 19 dez. 2025..9788522109241.

DI VAIO, Assunta *et al.* Artificial intelligence and business models in the sustainable development goals perspective: A systematic literature review. **Journal of Business Research** v. 121, p. 283–314, 1 dez. 2020. Acesso em: 3 fev. 2025.

DINH, Ngoc Hieu; ROH, Young Sook; TRUONG, Gia Toai. Shear strength model of FRP-reinforced concrete beams without shear reinforcement. **Structures** v. 64, p. 106520, 1 jun. 2024. Acesso em: 19 fev. 2025.

EUROCODE 2. **Design of concrete structures - Part 1-1: General rules and rules for buildings**. Brussels: [s.n.], 2004.

FARIDMEHR, Iman *et al.* Hybrid intelligence framework for optimizing shear capacity of lightweight FRP-reinforced concrete beams. **International Journal of Lightweight Materials and Manufacture** v. 8, n. 1, p. 14–27, 1 jan. 2025. Acesso em: 19 fev. 2025.

FATHALLA, Eissa; TANAKA, Yasushi; MAEKAWA, Koichi. Remaining fatigue life assessment of in-service road bridge decks based upon artificial neural networks. **Engineering Structures** v. 171, p. 602–616, 15 set. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029618306163?via%3Dihub>. Acesso em: 25 jan. 2026.

FENG, De Cheng *et al.* Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. **Construction and Building Materials** v. 230, p. 117000, 10 jan. 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950061819324420?via%3Dihub>. Acesso em: 25 jan. 2026.

FENG, De-Cheng *et al.* Interpretable XGBoost-SHAP Machine-Learning Model for Shear Strength Prediction of Squat RC Walls. **Journal of Structural Engineering** v. 147, n. 11, p. 04021173, 26 ago. 2021. Disponível em: [/doi/pdf/10.1061/%28ASCE%29ST.1943-541X.0003115?download=true](https://doi.org/10.1061/%28ASCE%29ST.1943-541X.0003115?download=true). Acesso em: 25 jan. 2026.

FIB BULLETIN 14. **Externally bonded FRP reinforcement for RC structures**. Lausanne, Switzerland: International Federation for Structural Concrete, 2001. “July 2001.” FRP strengthening materials and techniques -- Basis of design and safety concept -- Flexural strengthening -- Strengthening in shear and torsion -- Confinement -- Detailing rules -- Practical execution and quality control -- Special design considerations and environmental effects.2883940541.

FU, Bo; FENG, De Cheng. A machine learning-based time-dependent shear strength model for corroded reinforced concrete beams. **Journal of Building Engineering** v. 36, p. 102118, 1 abr. 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352710220337505?via%3Dihub>. Acesso em: 25 jan. 2026.

GHARBIA, Marwan *et al.* Robotic technologies for on-site building construction: A systematic review. **Journal of Building Engineering** v. 32, p. 101584, 1 nov. 2020. Acesso em: 3 fev. 2025.

GRUS, Joel. **Data science do zero: Noções fundamentais com Python**. 2. ed. Rio de Janeiro: Alta Books, 2021..

HAO, Z H *et al.* Durability of FRP-to-concrete bonded joints subjected to 110 months accelerated laboratory and field exposure. **ENGINEERING STRUCTURES** v. 305, 2024.

HARLE, Shrikant M. Durability and long-term performance of fiber reinforced polymer (FRP) composites: A review. **Structures** v. 60, p. 105881, 1 fev. 2024. Acesso em: 12 jan. 2025.

HAYKIN, Simon. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001..

HOLLAWAY, L. Polymer Composites for Civil and Structural Engineering. **Polymer Composites for Civil and Structural Engineering**, 1993. Acesso em: 16 jun. 2024.

KAR, Swapnasarit; BISWAL, K C. FRP shear contribution prediction for U-wrapped RC T-beams using a soft computing tool. **Structures** v. 27, p. 1093–1104, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352012420302988>.

KARDOVSKYI, Yurii; MOON, Sungwoo. Artificial intelligence quality inspection of steel bars installation by integrating mask R-CNN and stereo vision. **Automation in Construction** v. 130, p. 103850, 1 out. 2021. Acesso em: 3 fev. 2025.

KHALIFA, Ahmed *et al.* Contribution of Externally Bonded FRP to Shear Capacity of RC Flexural Members. **Journal of Composites for Construction** v. 2, n. 4, p. 195–202, 1 nov. 1998. Disponível em: <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%291090-0268%281998%292%3A4%28195%29>. Acesso em: 8 fev. 2025.

KHODADADI, Nima *et al.* Fiber-reinforced polymer (FRP) in concrete: A comprehensive survey. **Construction and Building Materials** v. 432, p. 136634, 21 jun. 2024. Acesso em: 16 jun. 2024.

KONG, Q Z *et al.* A CNN-integrated percussion method for detection of FRP-concrete interfacial damage with FEM reconstruction. **STRUCTURAL HEALTH MONITORING-AN INTERNATIONAL JOURNAL** v. 22, n. 1, p. 216–231, 2023.

KOTYNIA, Renata. **Wzmacnianie żelbetowych belek na ścianie za pomocą kompozytów polimerowych**. Dysertacje – Politechniki Łódzkiej, Łódz, 2011. Disponível em: <http://doi.org/10.34658/zn.rn.2011.1106.415>. Acesso em: 9 fev. 2025.

LOPES, Isaia Lima; SANTOS, Flávia Aparecida Oliveira; PINHEIRO, Carlos Alberto Murari. **Inteligência artificial**. 1. ed. Rio de Janeiro: Elsevier, 2014..

MACHADO, Ari de Paula. **Manual de Reforço das Estruturas de Concreto Armado com Fibras de Carbono**. [S.l.]: Viapol, 2010. Disponível em: <https://www.viapol.com.br/media/599376/arquivo-final-compactado.pdf>. Acesso em: 17 jun. 2024..

MAI, Thu Giang *et al.* Decoding a decade: The evolution of artificial intelligence in security, communication, and maintenance within the construction industry. **Automation in Construction** v. 165, p. 105522, 1 set. 2024. Acesso em: 2 fev. 2025.

MAKHLOUF, M H *et al.* Experimental and numerical study of shear strengthening of reinforced concrete beams using jute fiber reinforced polymers (JFRP). **JOURNAL OF BUILDING ENGINEERING** v. 86, 2024.

MAMDOUH, Hala *et al.* Concrete contribution to shear resistance of GFRP-RC beams under fire exposure. **Case Studies in Construction Materials** v. 21, p. e04109, 1 dez. 2024. Acesso em: 19 fev. 2025.

MANGALATHU, Sujith *et al.* Rapid seismic damage evaluation of bridge portfolios using machine learning techniques. **Engineering Structures** v. 201, p. 109785, 15 dez. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029619328068?via%3Dihub>. Acesso em: 25 jan. 2026.

MANGALATHU, Sujith; JEON, Jong Su. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques. **Engineering Structures** v. 160, p. 85–94, 1 abr. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029617329401?via%3Dihub>. Acesso em: 25 jan. 2026.

MANGALATHU, Sujith; JEON, Jong-Su. Machine Learning–Based Failure Mode Recognition of Circular Reinforced Concrete Bridge Columns: Comparative Study. **Journal of Structural Engineering** v. 145, n. 10, p. 04019104, 6 ago. 2019. Disponível em: [/doi/pdf/10.1061/%28ASCE%29ST.1943-541X.0002402?download=true](https://doi/pdf/10.1061/%28ASCE%29ST.1943-541X.0002402?download=true). Acesso em: 25 jan. 2026.

MANZOOR, Bilal *et al.* Influence of Artificial Intelligence in Civil Engineering toward Sustainable Development—A Systematic Literature Review. **Applied System Innovation** 2021, Vol. 4, Page 52 v. 4, n. 3, p. 52, 6 ago. 2021. Disponível em: <https://www.mdpi.com/2571-5577/4/3/52/htm>. Acesso em: 3 fev. 2025.

MOHAMMADI, A; BARROS, J A O; SENA-CRUZ, J. A novel design model for predicting the shear resistance of reinforced concrete beams strengthened with EBR-CFRP systems. **COMPOSITE STRUCTURES** v. 331, 2024.

MOHAMMADI, Amirhossein; BARROS, Joaquim A O; SENA-CRUZ, José. A new model for predicting the shear strength of RC beams strengthened with externally bonded FRP sheets. **Composite Structures** v. 319, p. 117081, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822323004257>.

MOHAMMADI, Amirhossein; BARROS, Joaquim A.O.; SENA-CRUZ, José. A novel design model for predicting the shear resistance of reinforced concrete beams strengthened with EBR-CFRP systems. **Composite Structures** v. 331, p. 117901, 1 mar. 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822324000291>. Acesso em: 29 abr. 2025.

MOHAMMADI, Amirhossein; BARROS, Joaquim A.O.; SENA-CRUZ, José. An interpretable machine learning-based model for shear resistance prediction of CFRP-strengthened RC beams using experimental and synthetic dataset. **Composite Structures** v. 351, p. 118632, 1 jan. 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822324007608>. Acesso em: 5 jan. 2026.

MORFIDIS, Konstantinos; KOSTINAKIS, Konstantinos. Approaches to the rapid seismic damage prediction of r/c buildings using artificial neural networks. **Engineering Structures** v. 165, p. 120–141, 15 jun. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029617336581?via%3Dihub>. Acesso em: 25 jan. 2026.

NADERPOUR, H; ALAVI, S A. A proposed model to estimate shear contribution of FRP in strengthened RC beams in terms of Adaptive Neuro-Fuzzy Inference System. **Composite Structures** v. 170, p. 215–227, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822316327775>.

NADERPOUR, H.; POURSAEIDI, O.; AHMADI, M. Shear resistance prediction of concrete beams reinforced by FRP bars using artificial neural networks. **Measurement** v. 126, p. 299–308, 1 out. 2018. Acesso em: 20 fev. 2025.

OLIVEIRA, Jonathas Iohanathan Felipe De *et al.* Estudo da influência da variável alvo na estimativa da capacidade resistente ao cisalhamento de vigas de concreto armado reforçadas com FRP por técnicas de machine learning. **Caderno Pedagógico** v. 21, n. 3, p. 01–29, 6 mar. 2024.

OLIVEIRA, Jonathas Iohanathan Felipe. **Reforço ao cisalhamento de vigas de concreto armado utilizando compósitos FRP**. Tese de doutorado – Universidade de Brasília, Brasília, 2024.

OLLER, Eva *et al.* Shear design of reinforced concrete beams with FRP longitudinal and transverse reinforcement. **Composites Part B: Engineering** v. 74, p. 104–122, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1359836815000037>.

OLLER, Eva; KOTYNIA, Renata; MARÍ, Antonio. Assessment of the existing models to evaluate the shear strength contribution of externally bonded frp shear reinforcements. **Composite Structures** v. 266, p. 113641, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822321001021>.

OLLER IBARS, Eva *et al.* Numerical analysis of reinforced concrete beams strengthened in shear by externally bonded (EB) fibre reinforced polymer (FRP) sheets. **Hormigón y Acero**

v. 69, n. 285, p. 113–120, 2018. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0439568917300372>.

PAN, Yue; ZHANG, Limao. Roles of artificial intelligence in construction engineering and management: A critical review and future trends. **Automation in Construction** v. 122, p. 103517, 1 fev. 2021. Acesso em: 3 fev. 2025.

PANAHI, M; ZAREEI, S A; IZADI, A. Flexural strengthening of reinforced concrete beams through externally bonded FRP sheets and near surface mounted FRP bars. **CASE STUDIES IN CONSTRUCTION MATERIALS** v. 15, 2021.

PERERA, R *et al.* Prediction of the ultimate strength of reinforced concrete beams FRP-strengthened in shear using neural networks. **Composites Part B: Engineering** v. 41, n. 4, p. 287–298, 2010. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S1359836810000387>.

PERERA, Ricardo; ARTEAGA, Angel; DIEGO, Ana De. Artificial intelligence techniques for prediction of the capacity of RC beams strengthened in shear with external FRP reinforcement. **Composite Structures** v. 92, n. 5, p. 1169–1175, 2010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263822309004504>.

RAHMAN, Jesika; ARAFIN, Palisa; MUNTASIR BILLAH, A H M. Machine learning models for predicting concrete beams shear strength externally bonded with FRP. **Structures** v. 53, p. 514–536, 2023a. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S2352012423005428>.

RAHMAN, Jesika; ARAFIN, Palisa; MUNTASIR BILLAH, A. H.M. Machine learning models for predicting concrete beams shear strength externally bonded with FRP. **Structures** v. 53, p. 514–536, 1 jul. 2023b. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S2352012423005428>. Acesso em: 6 jan. 2026.

REGONA, Massimo *et al.* Opportunities and Adoption Challenges of AI in the Construction Industry: A PRISMA Review. **Journal of Open Innovation: Technology, Market, and Complexity** v. 8, n. 1, p. 45, 1 mar. 2022. Acesso em: 3 fev. 2025.

REZA, Samy Muhammad; ALAM, M. Shahria; TESFAMARIAM, Solomon. Lateral load resistance of bridge piers under flexure and shear using factorial analysis. **Engineering Structures** v. 59, p. 821–835, 1 fev. 2014. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0141029613005968?via%3Dihub>. Acesso em: 25 jan. 2026.

RUSSELL, Stuart; NORVIG, Peter. **Inteligência artificial**. 3. ed. Rio de Janeiro: Elsevier, 2013..

SAYED, Ahmed M.; WANG, Xin; WU, Zhishen. Modeling of shear capacity of RC beams strengthened with FRP sheets based on FE simulation. **Journal of Composites for Construction** v. 17, n. 5, p. 687–701, 1 out. 2013. Acesso em: 9 maio 2024.

SMITH, Craig John; WONG, Andy T.C. Advancements in Artificial Intelligence-Based Decision Support Systems for Improving Construction Project Sustainability: A Systematic Literature Review. **Informatics 2022, Vol. 9, Page 43** v. 9, n. 2, p. 43, 13 maio 2022. Disponível em: <https://www.mdpi.com/2227-9709/9/2/43/htm>. Acesso em: 3 fev. 2025.

TABACHNICK, Barbara G.; FIDELL, Linda S.. **Using multivariate statistics**. [S.l.]: Pearson/Allyn & Bacon, 2007. 980 p. 5th ed.

TAGHIPOUR ANVARI, Ataollah; BABANAJAD, Saeed; GANDOMI, Amir H. Data-Driven Prediction Models For Total Shear Strength of Reinforced Concrete Beams With Fiber Reinforced Polymers Using An Evolutionary Machine Learning Approach. **Engineering Structures** v. 276, p. 115292, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029622013682>.

TANARSLAN, H M; SECER, M; KUMANLIOGLU, A. An approach for estimating the capacity of RC beams strengthened in shear with FRP reinforcements using artificial neural networks. **Construction and Building Materials** v. 30, p. 556–568, 2012. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950061811006854>.

TANG, Yixing *et al.* Shear performance prediction of RC beams shear-strengthened with FRP sheet: A machine learning driven design-oriented method. **Engineering Structures** v. 334, p. 120240, 1 jul. 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029625006315#bib32>. Acesso em: 25 jan. 2026.

VAN HONG BUI, Linh. Developed method for analyzing maximum shear capacity of RC beams retrofitted with embedded through-section FRP reinforcement. **Structures** v. 71, p. 108123, 1 jan. 2025. Acesso em: 19 fev. 2025.

WAKJIRA, Tadesse Gameda; EBEAD, Usama; ALAM, M. Shahria. Machine learning-based shear capacity prediction and reliability analysis of shear-critical RC beams strengthened with inorganic composites. **Case Studies in Construction Materials** v. 16, p. e01008, 1 jun. 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214509522001401>. Acesso em: 5 jan. 2026.

WANG, Chenxin *et al.* Shear strength prediction of FRP-strengthened concrete beams using interpretable machine learning. **Construction and Building Materials** v. 407, p. 133553, 2023a. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950061823032701>.

WANG, Chenxin *et al.* Shear strength prediction of FRP-strengthened concrete beams using interpretable machine learning. **Construction and Building Materials** v. 407, p. 133553, 1 dez. 2023b. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950061823032701>. Acesso em: 6 jan. 2026.

WANG, Shiqi *et al.* Prediction and optimization model of sustainable concrete properties using machine learning, deep learning and swarm intelligence: A review. **Journal of Building Engineering** v. 80, p. 108065, 1 dez. 2023. Acesso em: 2 fev. 2025.

WANG, Yifeng; WANG, Kan; ZHANG, Chuck. Applications of artificial intelligence/machine learning to high-performance composites. **Composites Part B: Engineering** v. 285, p. 111740, 1 out. 2024. Acesso em: 2 fev. 2025.

WANG, Zhangxiang *et al.* Machine learning-based prediction and interpretability analysis of flexural capacity for CFRP-strengthened RC beams. **Case Studies in Construction Materials** v. 23, p. e05203, 1 dez. 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214509525010010>. Acesso em: 5 jan. 2026.

WAQAS, Rana Muhammad; ELAHI, Ayub; KIRGIZ, Mehmet Serkan. Experimental and finite element analysis of shear deficient of reinforced concrete beam retrofitted externally with carbon fiber reinforced polymer sheet. **Structures** v. 72, p. 108232, 1 fev. 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352012425000463>. Acesso em: 7 jan. 2026.

WEINSTEIN, Jordan C *et al.* Bridge Damage Identification Using Artificial Neural Networks. **Journal of Bridge Engineering** v. 23, n. 11, p. 04018084, 1 nov. 2018. Disponível em: [/doi/pdf/10.1061/%28ASCE%29BE.1943-5592.0001302?download=true](https://doi/pdf/10.1061/%28ASCE%29BE.1943-5592.0001302?download=true). Acesso em: 25 jan. 2026.

YAN, Wangchen *et al.* Probabilistic machine learning approach to bridge fatigue failure analysis due to vehicular overloading. **Engineering Structures** v. 193, p. 91–99, 15 ago. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0141029618334345?via%3Dihub>. Acesso em: 25 jan. 2026.

YU, Yang *et al.* A novel optimised self-learning method for compressive strength prediction of high performance concrete. **Construction and Building Materials** v. 184, p. 229–247, 30 set. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S095006181831626X?via%3Dihub>. Acesso em: 25 jan. 2026.

YUAN, Cheng *et al.* Bayesian optimization for selecting efficient machine learning regressors to determine bond-slip model of FRP-to-concrete interface. **Structures** v. 39, p. 351–364, 1 maio 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352012422002119>. Acesso em: 5 jan. 2026.

YUMNAM, Mahesh *et al.* Inspection of concrete structures externally reinforced with FRP composites using active infrared thermography: A review. **Construction and Building Materials** v. 310, p. 125265, 6 dez. 2021. Acesso em: 20 fev. 2025.

ZHOU, C Y *et al.* Using end buckles to improve debonding resistance in FRP-bonded precracked RC beams. **ADVANCES IN STRUCTURAL ENGINEERING** v. 26, n. 1, p. 108–120, 2023.

ZHOU, Ying; HUANG, Zhewen; LU, Yiqiu. Machine learning-aided accelerated prediction of seismic response in CFRP-RC columns. **Journal of Building Engineering** v. 119, p. 115324, 1 fev. 2026. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352710226001452>. Acesso em: 25 jan. 2026.