



**INSTITUTO LATINO-AMERICANO DE
TECNOLOGIA, INFRAESTRUTURA E
TERRITÓRIO (ILATIT)**

**PROGRAMA DE PÓS-GRADUAÇÃO Em
ENGENHARIA CIVIL (PPGECI)**

**AVALIAÇÃO DE ABORDAGEM INTEGRADA ENTRE MEF POSICIONAL E
APRENDIZADO DE MÁQUINA PARA A MODELAGEM EM MESOESCALA DO
CONCRETO**

JAIRO ORLANDO FUENTES BARRETO



**INSTITUTO LATINO-AMERICANO DE
TECNOLOGIA, INFRAESTRUTURA E TERRITÓRIO
(ILATIT)**

**PROGRAMA DE PÓS-GRADUAÇÃO Em
ENGENHARIA CIVIL (PPGECI)**

**AVALIAÇÃO DE ABORDAGEM INTEGRADA ENTRE MEF POSICIONAL E
APRENDIZADO DE MÁQUINA PARA A MODELAGEM EM MESOESCALA DO
CONCRETO**

JAIRO ORLANDO FUENTES BARRETO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal da Integração Latino-Americana, como requisito para a obtenção do título de Mestre em Engenharia Civil.

Orientador: Prof. Dr. Emerson Felipe Félix

Foz do Iguaçu
2026

JAIRO ORLANDO FUENTES BARRETO

**AVALIAÇÃO DE ABORDAGEM INTEGRADA ENTRE MEF POSICIONAL E
APRENDIZADO DE MÁQUINA PARA A MODELAGEM EM MESOESCALA DO
CONCRETO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal da Integração Latino-Americana, como requisito para a obtenção do título de Mestre em Engenharia Civil.

BANCA EXAMINADORA

Orientador: Prof. Dr. Emerson Felipe Félix
UNESP

Prof^a. Dra. Mariana Correia Posterli
UFMS

Prof. Dra. Lisiane Pereira Prado
FEIS-UNESP

Foz do Iguaçu, 2 de julho de 2026.

Catálogo elaborado pelo Setor de Tratamento da Informação
Catálogo de Publicação na Fonte. UNILA - BIBLIOTECA LATINO-AMERICANA - CENTRAL

B273a

Barreto, Jairo Orlando Fuentes.

Avaliação de abordagem integrada entre MEF posicional e aprendizado de máquina para a modelagem em mesoescala do concreto / Jairo Orlando Fuentes Barreto. - Foz do Iguaçu, 2026.

147 fls.: il.

Universidade Federal da Integração Latino-Americana, Engenharia Civil, Pós-Graduação em Engenharia Civil.

Orientador: Emerson Felipe Félix.

1. Concreto - Pesquisa. 2. Modelagem de informação da construção. 3. Porosidade. 4. Redes neurais (Computação). I. Félix, Emerson Felipe. II.

DEDICATÓRIA

Dedico este trabalho, em especial, à minha mãe, que sempre acreditou em mim, mesmo nos momentos mais difíceis. Sua força, amor e dedicação, me inspiram todos os dias a continuar e nunca desistir dos meus sonhos.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me guiar e dar forças para superar os desafios, e por me conceder a saúde necessária para alcançar este sonho.

Aos meus pais, Himelda e José, meus agradecimentos mais especiais, pois sempre acreditaram em mim. Sou a pessoa que sou hoje porque vocês continuaram ao meu lado, mesmo com a distância que nos separa.

Agradeço ao meu orientador Emerson Felix não só pela constante orientação neste trabalho, mas, sobretudo, por sua paciência e persistência para que juntos pudéssemos chegar até onde chegamos.

A minha amiga Nathalia Marques, que sempre esteve à disposição para me ajudar em cada etapa do trabalho.

Aos professores das disciplinas cursadas no mestrado, por todo o seu conhecimento e pelas experiências compartilhadas em tão pouco tempo.

Aos colegas de curso pelo companheirismo e pelas boas conversas durante a execução dos trabalhos.

Agradeço também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro por meio da bolsa de estudos, que foi essencial para que eu pudesse me dedicar plenamente às atividades do mestrado. Este trabalho também contou com financiamento da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (Processo nº 2023/04364-9).

“O temor do SENHOR é o princípio da sabedoria, e o conhecimento do Santo é entendimento. Porque, por meu intermédio, os seus dias serão multiplicados e anos serão acrescentados à sua vida. Se você for sábio, a sabedoria será a sua recompensa.”

Provérbios 9:10-13

RESUMO

O comportamento mecânico do concreto é influenciado pela heterogeneidade de sua mesoestrutura, composta por matriz cimentícia, agregados e vazios. Embora a modelagem em mesoescala permita representar de forma mais realista os campos de tensões e deformações, a incorporação da porosidade em modelos numéricos ainda representa um desafio devido à dificuldade de sua quantificação experimental e de sua representação computacional. Nesse contexto, este trabalho investiga abordagens integradas entre o Método dos Elementos Finitos com versão Posicional (MEFP) e Redes Neurais Artificiais (RNAs) para avaliar e simular o comportamento mecânico do concreto em mesoescala, no regime elástico linear. Inicialmente, foi desenvolvido um modelo de RNA para predição do índice de vazios a partir de parâmetros de dosagem e de composição do concreto. O modelo apresentou bom desempenho, alcançando coeficientes de determinação de 0,90 e 0,84 nas fases de treinamento e de teste, respectivamente. Em seguida, com a aplicação de um código com o método dos elementos finitos posicional, acoplado ao modelo de predição do índice de vazios e o modelo reológico de Voigt, investigaram-se duas estratégias para a incorporação da porosidade nos modelos numéricos: (i) representação indireta dos vazios por meio da penalização das propriedades mecânicas da matriz de argamassa, utilizando os índices de vazios estimados pela RNA; e (ii) representação explícita dos vazios como descontinuidades geométricas na mesoestrutura. Os resultados mostraram que a desconsideração da porosidade leva à superestimação da rigidez do concreto e que o aumento do tamanho dos agregados promove maior heterogeneidade dos campos mecânicos e a redução do módulo de elasticidade equivalente. Entre as estratégias avaliadas, a representação indireta da porosidade apresentou o melhor desempenho, com erro percentual absoluto médio (MAPE) de 1,03% em relação aos resultados de campanhas experimentais da literatura, enquanto a modelagem sem considerar os vazios apresentou MAPE de 7,85% e a representação explícita dos vazios, de 13,73%. É importante pontuar que, na estratégia avaliada, apenas a matriz de argamassa apresentou o efeito dos vazios incorporados, o que pode ter ocasionado maior perda de rigidez nos modelos com representação explícita dos vazios. Apesar da menor precisão na representação da rigidez do compósito, a segunda estratégia apresenta vantagens importantes do ponto de vista físico, uma vez que representa explicitamente as descontinuidades geométricas da mesoestrutura, o que permitiria capturar mecanismos locais de concentração de tensões e deformações que não são reproduzidos pela abordagem homogeneizada. Para melhorar as simulações, seria necessário determinar com maior precisão o módulo de elasticidade dos agregados graúdos, dado que não é de fácil obtenção. De modo geral, os resultados permitiram inferir que a integração entre aprendizado de máquina e modelagem por elementos finitos constitui uma estratégia eficiente para incorporar os efeitos da porosidade em modelos mesoescalares.

Palavras-chave: Modelagem; Mesoescala; Índice de Vazios; Redes Neurais Artificiais.

ABSTRACT

The mechanical behavior of concrete is influenced by the heterogeneity of its mesostructure, composed of a cementitious matrix, aggregates, and voids. Although mesoscale modeling enables a more realistic representation of stress and strain fields, incorporating porosity into numerical models remains challenging due to difficulties in its experimental quantification and computational representation. In this context, this work investigates integrated approaches that combine the Positional Finite Element Method (PFEM) and Artificial Neural Networks (ANNs) to evaluate and simulate the mechanical behavior of concrete at the mesoscale in the linear-elastic regime. Initially, an ANN model was developed to predict the void ratio from concrete mix proportions and composition parameters. The model demonstrated good performance, achieving coefficients of determination of 0.90 and 0.84 in the training and testing phases, respectively. Subsequently, using a code based on the positional finite element method coupled with the void ratio prediction model and the Voigt rheological model, two strategies for incorporating porosity into numerical models were investigated: (i) indirect representation of voids through the penalization of the mechanical properties of the mortar matrix, using the void ratios estimated by the ANN; and (ii) explicit representation of voids as geometric discontinuities within the mesostructured. The results showed that neglecting porosity leads to an overestimation of concrete stiffness, and that increasing aggregate size promotes greater heterogeneity in the mechanical fields and reduces the equivalent elastic modulus. Among the evaluated strategies, the indirect representation of porosity exhibited the best performance, with a mean absolute percentage error (MAPE) of 1.03% relative to experimental results from the literature, whereas modeling without considering voids yielded a MAPE of 7.85%, and explicit void representation resulted in a MAPE of 13.73%. It is important to note that in the evaluated strategy, only the mortar matrix accounted for the effect of voids, which may have led to greater stiffness loss in models with explicit void representation. Despite lower accuracy in predicting composite stiffness, the second strategy offers key physical advantages by explicitly modeling the geometric discontinuities of the mesostructure, thereby capturing local stress and strain concentration mechanisms that are not reproduced by the homogenized approach. To improve the simulations, a more precise determination of the elastic modulus of coarse aggregates would be necessary, given that it is difficult to obtain. Overall, the results indicate that integrating machine learning with finite element modeling constitutes an efficient strategy for incorporating porosity effects into mesoscale models.

Keywords: Modeling; Mesoscale; Void Ratio; Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1 – Representação multiescala do concreto e do elemento estrutural.....	13
Figura 2 – Resultados de simulação numérica e estudo experimental: (a) curvas tensão-deformação de corpos de prova de concreto submetidos à compressão uniaxial; (b) modos de falha e distribuição de fissuras reais; (c) modos de falha e distribuição de fissuras na modelagem.	14
Figura 3 – Representação de uma rede neural com múltiplas camadas ocultas.	17
Figura 4. Representação de compósitos cimentícios em diferentes escalas.	26
Figura 5. Representação em mesoescala do concreto por discretização por elementos finitos.	27
Figura 6. Sobreposição de malhas modelo mesoescala.	28
Figura 7. Arranjo geométrico de modelos com redes.	29
Figura 8. (a) Mapeamentos das propriedades dos membros da rede (agregado, matriz e ligação) e (b) Representação esquemática de um elemento de viga de dois nós.	30
Figura 9. (a) Célula unitária e (b) rede discreta de elemento de viga.	32
Figura 10. Geometria e malha do modelo de fratura DEM no modo I.	33
Figura 11. a) Modelo experimental-cubo de concreto e b) Modelos numérico DEM.	33
Figura 12. Modelagem com agregados em forma poligonal.	35
Figura 13. Malha com representação trifásica do material.	36
Figura 14. Modelo: a) agregados elípticos 2D e vazios circulares; b) agregados elipsoidais 3D e vazios esféricos.	37
Figura 15. Estrutura 3D dos agregados em mesoescala e visualização do compósito em corte.	38
Figura 16. a) Diâmetros dos agregados e b) forma dos agregados discretizados.	39
Figura 17. Diâmetro dos agregados utilizados no modelo mesoescala.	39
Figura 18. Modelos cúbicos em mesoescala com diferentes dimensões e tamanhos de agregados equivalentes.	40
Figura 19. Arquitetura de árvores de decisão.	48
Figura 20. Diagrama de Taylor para comparação de performance.	49
Figura 21. Arquitetura da rede neural escolhida.	50
Figura 22. Modelo de arquitetura da rede neural escolhida.	51
Figura 23. Representação gráfica da porosidade calculada e estimada.	53
Figura 24. Representação de neurônio biológico.	54
Figura 25. a) neurônio biológico e b) neurônio artificial.	54
Figura 26. Esquema de processamento de informações do neurônio artificial.	55
Figura 27. Função de ativação degrau.	56
Figura 28. Função de ativação degrau bipolar.	57
Figura 29. Função de ativação do tipo rampa simétrica.	58
Figura 30. Função de ativação logística.	58
Figura 31. Função de ativação tangente hiperbólica para diferentes valores de λ	59
Figura 32. Função de ativação gaussiana.	59
Figura 33. Função de ativação Linear.	60
Figura 34. Disposição de RNAs feedforward.	61
Figura 35. Exemplo de RNA com uma única camada de processamento (oculta).	62
Figura 36. Rede feedforward de camadas múltiplas.	62
Figura 37. Rede com arquitetura recorrente.	63
Figura 38. Rede com arquitetura reticulada.	63
Figura 39. Rede Perceptron.	65

Figura 40. Rede Adaline.....	66
Figura 41. Perceptron de múltiplas camadas com duas camadas ocultas.	67
Figura 42. Fluxograma do algoritmo de backpropagation.	68

LISTA DE TABELAS

Tabela 1 . Algoritmos de Aprendizado de Máquina não supervisionado.....	46
---	----

SUMÁRIO


1 INTRODUÇÃO	13
1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO	13
1.2 OBJETIVOS.....	18
1.2.1 <i>Objetivo geral</i>	18
1.2.2 <i>Objetivos específicos</i>	18
1.3 METODOLOGIA EMPREGADA NO ESTUDO.....	18
1.4 ESTRUTURA DA DISSERTAÇÃO	21
2 FUNDAMENTAÇÃO TEÓRICA	23
2.1 MODELOS DE PREDIÇÃO DO MÓDULO DE ELASTICIDADE DO CONCRETO	23
2.2 MODELAGEM DO CONCRETO EM MESOESCALA.....	26
2.3 CARACTERIZAÇÃO E DISCRETIZAÇÃO DO COMPÓSITO.....	33
2.4 DEFINIÇÃO DO ÍNDICE DE VAZIOS – POROSIDADE DO CONCRETO	42
2.4.1 <i>Formulações analíticas</i>	43
2.4.2 <i>Modelos baseados em Aprendizado de Máquina</i>	45
2.5 REDES NEURAIS ARTIFICIAIS.....	53
2.5.1 <i>Função de ativação</i>	56
2.5.2 <i>Arquitetura das RNAs</i>	60
2.5.3 <i>Modelos de RNAs</i>	64
3 MATERIAIS E MÉTODOS: FORMATO ARTIGOS	70
4 CONCLUSÕES	143
4.1 CONSIDERAÇÕES FINAIS.....	143
4.2 LIMITAÇÕES DO ESTUDO	145
4.3 SUGESTÕES PARA TRABALHOS FUTUROS	146
5 REFERÊNCIAS.....	147

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO


Com o avanço da capacidade computacional e o crescente interesse por abordagens numéricas, técnicas como o Método dos Elementos Finitos (MEF) vêm sendo cada vez mais aplicadas à modelagem do concreto em macro e mesoescala (Figura1). Essa abordagem permite representar o concreto como um material heterogêneo, considerando a distribuição espacial de suas fases constituintes (matriz de argamassa, agregado e interface), o que viabiliza simulações mais realistas do comportamento mecânico do material. Estudos recentes demonstram o potencial do MEF na reprodução de fenômenos estruturais complexos e na análise de propriedades físico-mecânicas, como a rigidez efetiva ou a concentração de tensões e progressão de fissuras (Figura 2) ,a partir de representações detalhadas do compósito (LEE et al., 2009, ZHU; CHEN, 2012 , ZHOU; LI; MA, 2014).

Figura 1 – Representação multiescala do concreto e do elemento estrutural.



Fonte: Editado de Baduge et al. (2025).

Figura 2 – Resultados de simulação numérica e estudo experimental: (a) curvas tensão-deformação de corpos de prova de concreto submetidos à compressão uniaxial; (b) modos de falha e distribuição de fissuras reais; (c) modos de falha e distribuição de fissuras na modelagem.



Fonte: Zhang; Xie; Feng, (2022).

A depender das dimensões do elemento a ser simulado, os modelos numéricos de concreto são tipicamente classificados em: microescala (10^{-6} a 10^{-4} m), mesoescala (10^{-3} a 10^{-1} m) e macroescala (maior que 1 m) (YANG et al., 2026). Na macroescala, o material é tratado como homogêneo, com propriedades médias equivalentes, o que torna essa abordagem adequada para análises estruturais globais. Já na mesoescala, o concreto é representado de forma explícita, considerando seus principais constituintes, como a matriz de argamassa, os agregados, vazios e a zona de transição interfacial (VIEIRA, 2021). Na microescala, o foco está na estrutura interna da pasta de cimento e na presença de microporos (MURSHIDA et al., 2023).

A modelagem em mesoescala destaca-se por permitir a representação heterogênea do concreto, sendo especialmente adequada para a análise de fenômenos como a concentração de tensões, o início de fissuras e sua propagação (THILAKARATHNA et al., 2020). Nesse nível, torna-se possível avaliar a influência da distribuição e das propriedades dos agregados, bem como da interface com a matriz, sobre o comportamento global do material (WANG et al., 2015a).

Para a modelagem numérica desses problemas, o Método dos Elementos Finitos (MEF) é amplamente utilizado. Esse método consiste na discretização do domínio em elementos menores, nos quais são calculados os campos de deslocamentos, tensões e deformações (AZEVEDO, 2003). Essa abordagem permite analisar problemas complexos, incluindo materiais heterogêneos e comportamentos não lineares.

Na modelagem em mesoescala convencional, cada fase do concreto pode exigir uma malha própria ou uma discretização compatível entre a matriz, os agregados e o ITZ. Isso gera uma dificuldade importante: quanto maior o nível de detalhamento da geometria dos agregados e da zona de transição, maior tende a ser o número de elementos, nós e graus de liberdade do problema (VIEIRA et al., 2024). Além disso, quando se exige compatibilidade entre as malhas das diferentes fases, a geração da malha torna-se mais complexa, especialmente quando os agregados são distribuídos aleatoriamente no domínio. Essa problemática aumenta o custo computacional e dificulta a criação de modelos com grande quantidade de partículas (RAMOS et al., 2021).

Como alternativa, o Método dos Elementos Finitos Posicional (MEFP) permite representar sistemas compósitos por meio de uma estratégia de embutimento ou de sobreposição de malhas (CODA & PACCOLA, 2009). Nessa formulação, a malha da matriz, por exemplo, a argamassa, é gerada inicialmente. Em seguida, são geradas malhas independentes para os agregados ou inclusões. Essas malhas são então sobrepostas à malha da matriz, sem necessidade de coincidência entre os nós das diferentes fases (MOURA, 2015; RAMOS et al., 2021). Segundo Moura (2015) a formulação permite considerar a interação matriz-partícula sem coincidência entre as malhas e sem aumento do número de graus de liberdade, assumindo aderência perfeita entre as fases.

Apesar dos avanços significativos no uso de técnicas numéricas para modelar o comportamento do concreto em mesoescala, grande parte dos modelos desenvolvidos ainda carece de aplicabilidade prática, especialmente quanto à calibração dos parâmetros físico-mecânicos. Isso ocorre principalmente devido à exigência de parâmetros difíceis de definir, associados a cada uma das fases que compõem o compósito, especialmente quando se considera a porosidade como um meio a ser simulado. A representação dos vazios ainda constitui um desafio relevante, uma vez que sua presença afeta diretamente a rigidez e a resistência do concreto,

mas sua quantificação e distribuição são difíceis de determinar experimentalmente (WANG et al., 2015a).


Nesse cenário, o Aprendizado de Máquina surge como uma estratégia promissora para ampliar a aplicabilidade dos modelos baseados em MEF. Ao treinar algoritmos de Aprendizado de Máquina com dados relacionados às propriedades físico-mecânicas de concretos, é possível definir modelos simplificados para a predição de parâmetros de difícil calibração, a exemplo da porosidade ou do índice de vazios (DEMIR, 2005, GOLAFSHANI; BEHNOOD, 2018, BEHNOOD; OLEK; GLINICKI, 2015).

O aprendizado é a principal característica que conecta as ferramentas computacionais da Inteligência Artificial (IA) ao comportamento humano, uma vez que a capacidade de aprender é central para a definição de inteligência. A IA busca justamente reproduzir essa habilidade em sistemas computacionais, permitindo que as máquinas aprendam com exemplos, se adaptem a novas situações e executem tarefas com desempenho semelhante ao dos seres humanos.

Segundo Hertzmann e Fleet, (2012), o Aprendizado de Máquina consiste em um conjunto de técnicas que possibilita ensinar os computadores a realizar tarefas por meio da apresentação de exemplos, dispensando a necessidade de programação explícita para cada cenário. Ao longo das últimas décadas, o avanço da IA possibilitou o surgimento de diversos métodos de aprendizado automático. Entre as técnicas mais consolidadas estão as Árvores de Decisão, usadas tanto para classificação quanto para regressão, e as Redes Neurais Artificiais (RNAs), ambas empregadas por aliarem bom desempenho preditivo a um custo computacional relativamente baixo.

As Redes Neurais Artificiais (RNAs) são inspiradas na estrutura e no funcionamento dos neurônios biológicos. As RNAs são compostas por unidades de processamento, denominadas neurônios artificiais, organizados em camadas interconectadas. Uma RNA do tipo feedforward é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como ilustrado na Figura 3. Cada conexão entre neurônios é ponderada por um valor ajustável, chamado de peso, que é ajustado durante o treinamento. Essa arquitetura permite que RNAs capturem padrões complexos em dados multivariados e tem sido aplicada com sucesso em tarefas de regressão, reconhecimento de padrões, análise de imagens e séries temporais.

Figura 3 – Representação de uma rede neural com múltiplas camadas ocultas.



Fonte: Própria autoria.

As RNAs se destacam por sua capacidade de modelar relações não lineares entre variáveis, sendo especialmente eficazes em contextos em que os mecanismos que regem o fenômeno não são completamente conhecidos ou são de difícil modelagem analítica. As redes neurais, em especial do tipo Multi-Layer Perceptron (MLP – com múltiplas camadas ocultas/de processamento), vêm sendo amplamente aplicadas na predição de propriedades como resistência à compressão (MORAES & SANTOS, 2022), módulo de elasticidade (MORETTI, 2010) e índice de vazios (SANTOS et al., 2024), demonstrando bom desempenho preditivo, inclusive em concretos com resíduos de construção e demolição (RCD), que apresentam significativa variabilidade nos valores dos parâmetros físico-mecânicos em função da heterogeneidade dos agregados de RCD (FROTTÉ et al., 2017; OLIVEIRA et al., 2023).

Diante do exposto, este trabalho tem como propósito avaliar estratégias numéricas para a simulação do comportamento mecânico do concreto, em regime elástico-linear, considerando o acoplamento do Método dos Elementos Finitos, com versão Posicional (MEFP), a um modelo de representação da porosidade do concreto baseado em RNAs do tipo MLP. A principal contribuição do estudo está na utilização de parâmetros de entrada de fácil obtenção, como proporções dos materiais, tipo de agregado e relação água/cimento, que, juntamente com o modelo baseado em RNAs, permitirão simular, em mesoescala, o comportamento do concreto, considerando três fases: argamassa, agregados graúdos e vazios.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Desenvolver uma metodologia híbrida, baseada no Método dos Elementos Finitos com versão posicional (MEFP) e em técnicas de Aprendizado de Máquina, para modelar o comportamento mecânico do concreto em mesoescala, em regime elástico-linear, considerando sua natureza heterogênea e utilizando parâmetros de entrada de fácil obtenção, como as proporções dos materiais constituintes.

1.2.2 Objetivos específicos

- Definir e analisar um banco de dados associado ao índice de vazios de concretos com agregados de diferentes origens;
- Desenvolver e validar um modelo de predição do índice de vazios do concreto baseando-se em RNAs do tipo MLP;
- Propor e avaliar estratégias numéricas para simular o comportamento mecânico do concreto em mesoescala por meio do MEFP.

1.3 METODOLOGIA EMPREGADA NO ESTUDO

A metodologia utilizada no presente trabalho envolveu seis etapas/processos principais, das quais: (i) revisão bibliográfica e definição de um banco de dados associados a porosidade do concreto; (ii) análise estatística e tratamento dos dados; (iii) treinamento, validação e teste de modelos de RNAs para predição do índice de vazios; (iv) proposição de estratégias numéricas para representar o concreto como um meio trifásico (argamassa, agregados graúdos e vazios) via MEFP; (v) análise de desempenho das estratégias numéricas investigadas; (vi) desenvolvimento dos textos da qualificação e defesa e, de artigos para divulgação dos resultados do trabalho.

A seguir, descrevem-se os processos metodológicos utilizados no trabalho:

- I. **Revisão bibliográfica e definição do banco de dados:** esta etapa se estendeu ao longo de todo o período de execução do trabalho, constituindo a base para as demais fases da pesquisa. Durante a revisão bibliográfica, foram coletados dados referentes ao índice de vazios de concretos com agregados de diferentes origens. A coleta foi

realizada por meio da análise de estudos disponíveis nas bases de dados CAFE, SciELO, Scopus e ScienceDirect, abrangendo tanto investigações experimentais quanto estudos de modelagem;

- II. **Análise estatística e tratamento dos dados:** nesta etapa, foi implementado um código em Python, utilizando a IDE Jupyter Notebook e as bibliotecas scikit-learn, Seaborn, Pandas, NumPy e Matplotlib, com o objetivo de viabilizar a análise e o processamento dos dados. Foram avaliadas a presença de dados duplicados e a identificação de outliers, cujas informações pudessem comprometer o desempenho do treinamento das RNAs. Também foi conduzida a análise estatística exploratória do conjunto de dados, visando caracterizar suas principais variáveis e distribuições;
- III. **Treinamento, validação e teste de modelos de RNAs para predição do índice de vazios:** foram desenvolvidos os códigos responsáveis pelo treinamento, validação e teste de Redes Neurais Artificiais (RNAs). Neste estudo, foram utilizadas RNAs do tipo feedforward, com até duas camadas ocultas, contendo, no máximo, 20 neurônios por rede e funções de ativação do tipo logística. A otimização dos pesos sinápticos foi realizada por meio do algoritmo Adam (*Adaptive Moment Estimation*), adotado para a minimização de funções objetivo estocásticas com gradientes de primeira ordem. O método baseia-se em estimativas adaptativas dos momentos de ordem inferior, apresentando vantagens como facilidade de implementação, eficiência computacional, baixo consumo de memória e eficiência no redimensionamento diagonal dos gradientes. Para o processo de modelagem, os dados foram particionados em conjuntos de treinamento (80%) e teste (20%), utilizando a técnica de amostragem estratificada para preservar a distribuição original do banco de dados. Adicionalmente, foi empregada a validação cruzada *k-fold*, com $k = 8$, a fim de evitar o supertreinamento e melhorar a capacidade de generalização do modelo. A implementação foi realizada em Python, utilizando a IDE Jupyter Notebook e a biblioteca *scikit-learn*;

IV. **Proposição de estratégias numéricas para representar o concreto como um meio trifásico (argamassa, agregado graúdo e vazios) via MEPP:** nesta etapa, utilizou-se um código computacional em Fortran para a simulação numérica de sólidos compósitos, com o objetivo de representar o concreto em mesoescala como um sistema trifásico, composto por matriz de argamassa, agregados graúdos e vazios. A modelagem considerou duas estratégias diferentes de representação do meio trifásico: (I) duas fases foram representadas (argamassa e agregados graúdos), com a incorporação da porosidade por meio da penalização da rigidez da argamassa; (II) a segunda estratégia considerou a incorporação dos vazios por meio de uma terceira fase, inserindo elementos finitos com rigidez negativa, de modo que a rigidez do material fosse nula nas regiões de existência dos poros. O modelo numérico de representação do compósito baseia-se no Método dos Elementos Finitos Posicional (MEFP), que permite a consideração natural da não linearidade geométrica por meio de uma formulação direta, sem introduzir novos graus de liberdade no sistema. A constituição mecânica dos materiais foi descrita com base na relação de Saint-Venant-Kirchhoff, apropriada para materiais elásticos submetidos a grandes deformações. A resolução dos sistemas de equações não lineares foi realizada pelo método iterativo incremental de Newton-Raphson, garantindo estabilidade e convergência durante as simulações. Para a discretização do domínio contínuo, utilizaram-se elementos finitos triangulares de ordem cúbica, aplicando-se polinômios de Lagrange para uma descrição precisa da geometria e dos campos de deslocamento. O modelo também inclui elementos finitos sobrepostos: elementos de partícula, que representarão os agregados graúdos e vazios. Os elementos sobrepostos são formulados com aproximação cúbica das posições nodais, assegurando a continuidade e a precisão no campo de deslocamentos. O acoplamento entre os elementos da matriz (tipo chapa) e os elementos de partícula foi realizado por meio da técnica de embutimento cinemático, conforme proposto por Vanalli, (2004) e aprimorado por Sampaio, Coda; Paccola, (2011), Coda; Paccola,

(2011), Moura, (2015) e Paccola; Coda, 2016. Essa técnica consiste em inserir os nós das partículas diretamente sobre os elementos finitos representativos da matriz, garantindo a compatibilidade cinemática sem a necessidade de reconfiguração da malha;

- V. **Análise de desempenho das estratégias investigadas:** foram realizadas análises comparativas entre as duas estratégias propostas e a modelagem em macroescala, a fim de avaliar a eficiência e praticidade na modelagem do concreto em mesoescala. Para as análises de desempenho, foram comparadas as curvas de tensão versus deformação e o módulo de elasticidade tangente inicial, associado ao regime elástico-linear do material. Para a comparação de desempenho, utilizaram-se os concretos do banco de dados definido na primeira etapa, com resultados provenientes de campanhas experimentais da literatura. Nas simulações, avaliou-se também o efeito da distribuição dos agregados e da dimensão característica dos agregados;
- VI. **Desenvolvimento dos textos da qualificação, da defesa e de artigos para divulgação dos resultados do trabalho:** Com o objetivo de disseminar os resultados obtidos ao longo deste estudo, dedicou-se à redação de artigos científicos e à dissertação.

1.4 ESTRUTURA DA DISSERTAÇÃO

O presente texto está estruturado em cinco capítulos, sendo que o primeiro introduz o tema tratado na pesquisa, indica os objetivos do estudo e apresenta a metodologia empregada.

O segundo capítulo apresenta um referencial teórico acerca dos temas tratados na pesquisa, abrangendo a modelagem numérica do comportamento mecânico do concreto, especialmente em mesoescala, e o uso de redes neurais artificiais na modelagem de parâmetros mecânicos do concreto.

Os processos metodológicos utilizados no desenvolvimento das simulações numéricas, assim como os resultados obtidos, são apresentados nos capítulos 3 e 4, em formato de artigos. No capítulo 3, é apresentado o desenvolvimento do modelo

preditivo do índice de vazios, com os resultados discutidos e comparados aos modelos da literatura. Já o capítulo 4 apresenta a análise comparativa das duas estratégias numéricas investigadas para representar o concreto em mesoescala.

O último capítulo apresenta as conclusões do estudo e propostas de trabalhos futuros, além de indicar as principais limitações da pesquisa.

Por fim, comenta-se que, ao longo do texto, foi utilizado o modelo de linguagem Gemini Pro 3.1 para revisão gramatical, adequação do vocabulário e redução de redundâncias verbais. O conteúdo intelectual, a análise e as interpretações desenvolvidas são de responsabilidade exclusiva do autor.

2 FUNDAMENTAÇÃO TEÓRICA

O presente capítulo aborda os modelos para estimativa do módulo de elasticidade e os fundamentos da modelagem numérica do concreto, com foco na discussão e comparação das principais técnicas numéricas utilizadas para representar o compósito em mesoescala. São analisados tanto os métodos empregados nas simulações quanto as estratégias de representação do material, considerando modelos bifásicos (argamassa + agregados graúdos) e trifásicos (aglomerantes + agregados + vazios), com suas respectivas implicações na precisão dos resultados. Ao final, introduzem-se as Redes Neurais Artificiais como ferramenta de modelagem de parâmetros físico-mecânicos do concreto, adotada neste estudo para a estimativa da porosidade, associada à rigidez efetiva inicial do compósito (volume efetivo versus volume teórico), parâmetro que subsidiará a modelagem trifásica do concreto em mesoescala.

2.1 MODELOS DE PREDIÇÃO DO MÓDULO DE ELASTICIDADE DO CONCRETO

O módulo de elasticidade é um parâmetro de grande importância no estudo do comportamento mecânico do concreto, especialmente quanto à sua deformabilidade (TOPÇU, 2005). O conhecimento do módulo é de suma importância no projeto de estruturas de concreto armado, pois constitui parâmetro para a avaliação do estado limite de serviço, por meio de verificações de deformação e de estabilidade global dos elementos das edificações.

Ao longo dos últimos anos, diversos modelos e formulações foram propostos com o intuito de estimar e prever o módulo de elasticidade do concreto, considerando os mais diversificados tipos, por exemplo, concreto para a construção de barragens (TOPÇU, 2005 ; VILARDELL et al., 1998), concreto contendo agregado reciclado (GOLAFSHANI ; BEHNOOD, 2018, GONZÁLEZ-TABOADA et al., 2016), concreto com adições minerais (UYSAL; TANYILDIZI, 2011), concreto sob altas temperaturas (MUKHERJEE; BISWAS, 1997, LEE et al., 2009) e concreto de baixa e alta resistência à compressão (YAN; SHI, 2010; DEMIR, 2008). Os modelos desenvolvidos dividem-se em formulações baseadas em resultados experimentais, em teoria da elasticidade e em fundamentos da mecânica dos sólidos compósitos.

Os modelos mais simplificados, obtidos por meio de regressões lineares e não lineares, utilizam a resistência à compressão do concreto (f_c) como único ou principal parâmetro para a estimativa do módulo de elasticidade, conforme apresentado nas Equações 1 (ACI Committee 318, 1995), 2 (CSA A23, 2024), 3 (CEB-FIP Model Code, 1990) e 4 (ABNT NBR 6118, 2023). A expressão proposta pela ABNT NBR 6118:2023 é amplamente empregada para concretos convencionais com resistência característica à compressão (f_{ck}) até 50 MPa e incorpora um coeficiente (αE) que considera a influência do tipo de agregado graúdo sobre o módulo de elasticidade do concreto.

A maioria desses modelos é recomendada por normas nacionais e internacionais devido à facilidade de manipulação e à coerência dos valores obtidos com sua utilização.

$$E_c = 4700\sqrt{f'_c} \quad \text{Equação 1}$$

$$E_c = 4500\sqrt{f'_c} \quad \text{Equação 2}$$

$$E_c = 10000(f'_c + 8)^{0.33} \quad \text{Equação 3}$$

$$E_c = \alpha E \cdot 5600\sqrt{f_{ck}} \quad \text{Equação 4}$$

Modelos mais sofisticados foram desenvolvidos com base na teoria da elasticidade, na reologia do concreto e na mecânica dos sólidos compósitos: Equações 5 (modelo de Voigt), 6 (modelo de Reuss), 7 (modelo de Hirsch), 8 (modelo de Hansen) e 9 (modelo de Counto) (ULRIK NILSEN; METHA; MONTEIRO, 1993). Estes modelos foram determinados considerando o concreto como um material bifásico, com uma fase referente à matriz cimentícia (argamassa) e outra aos agregados.

$$E_c = E_m V_m + E_a V_a \quad \text{Equação 5}$$

$$E_c = \left(\frac{V_m}{E_m} + \frac{V_a}{E_a} \right)^{-1} \quad \text{Equação 6}$$

$$E_c = \left[0.5 \left[\left(\frac{V_a}{E_a} + \frac{1 - V_a}{E_m} \right) + \left(\frac{1}{E_a V_a + (1 - V_a) E_m} \right) \right] \right]^{-1} \quad \text{Equação 7}$$

$$E_c = E_m \left(\frac{E_m V_m + (1 + V_a) E_a}{(1 + V_a) E_m + E_a V_m} \right) \quad \text{Equação 8}$$

$$E_c = \left[\frac{1 - \sqrt{V_a}}{E_m} + \frac{1}{\left(\frac{1 - \sqrt{V_a}}{\sqrt{V_a}} \right) E_m + E_a} \right]^{-1} \quad \text{Equação 9}$$

em que E_m é o módulo de elasticidade da matriz cimentícia, E_a é o módulo de elasticidade do agregado gráúdo, V_m e V_a referem-se, respectivamente, às porcentagens volumétricas da matriz cimentícia e dos agregados gráúdos.

Topçu, (2005) analisou os modelos descritos nas Eqs. (5–9) e verificou que estes se apresentam como uma alternativa eficiente para a estimativa do módulo de elasticidade de concretos de baixa e média resistência. Além disso, o autor observou, por meio da aplicação de modelos compósitos, que, para concretos de alta resistência, as formulações propostas por Voigt, Hirsch e Hansen (Eqs. 5, 7 e 8, respectivamente) são as mais indicadas para prever o módulo de elasticidade do material. Vale destacar, ainda, que muitos dos modelos existentes não são aplicáveis a concretos com agregados reciclados, de altíssima resistência ou autoadensáveis (com elevados teores de superplastificante).

A estimativa das propriedades mecânicas do concreto, como o módulo de elasticidade, é essencial para a concepção e a avaliação do desempenho das estruturas. Modelos analíticos, como os representados pelas Equações 5-9, dependem do conhecimento prévio dos módulos de elasticidade das fases constituintes do concreto (a matriz cimentícia e o agregado gráúdo), bem como de suas proporções volumétricas. Tais informações, embora muitas vezes disponíveis na etapa de dosagem, podem se tornar imprecisas ou indisponíveis, especialmente quando se trata de estruturas envelhecidas ou submetidas a condições ambientais severas. Nesse contexto, a necessidade de estimativas adicionais introduz incertezas e potenciais erros nas análises estruturais.


Além da resistência à compressão e das proporções volumétricas das fases constituintes, o módulo de elasticidade do concreto também é influenciado pelas propriedades mecânicas e pela natureza mineralógica do agregado gráúdo. Em geral, agregados com maior rigidez tendem a produzir concretos com maiores valores de módulo de elasticidade, evidenciando que a resposta mecânica do material depende não apenas da matriz cimentícia, mas também das características dos agregados empregados (LEAL et al., 2020).

Essa influência é reconhecida, inclusive, pela ABNT NBR 6118:2023, que incorpora o coeficiente (αE) na estimativa do módulo de elasticidade para considerar o efeito do tipo de agregado graúdo. Dessa forma, embora os modelos empíricos baseados exclusivamente na resistência à compressão apresentem simplicidade e ampla aplicação prática, a consideração das propriedades dos constituintes torna-se fundamental para uma representação mais realista do comportamento mecânico do concreto.

2.2 MODELAGEM DO CONCRETO EM MESOESCALA

O concreto pode ser representado como um sistema heterogêneo em diferentes escalas: macro, meso, micro e nano (EMERY et al., 2007). Em macroescala, o concreto é tratado como um material homogêneo. Já na mesoescala, ele é modelado como um compósito trifásico, composto por matriz de argamassa, agregados e pela zona de transição interfacial (ITZ), como ilustrado na Figura 4. Em microescala, a matriz de argamassa é composta por pasta de cimento e agregados finos e apresenta poros internos. Na nanoescala, a pasta de cimento é analisada com base nos poros capilares e na heterogeneidade nanométrica da microestrutura (NGUYEN; STROEVEN; SLUYS, 2012).

Figura 4. Representação de compósitos cimentícios em diferentes escalas.




Fonte: Modificado de Murshida, Jiyad e Nagarajan (2023).

Os modelos em mesoescala são empregados para investigar danos, características e parâmetros associados à fratura. Esses modelos possibilitam uma análise minuciosa da distribuição e interação entre os diversos componentes do concreto, proporcionando uma compreensão mais abrangente de seu comportamento (ZHANG et al., 2021).

Diversos métodos de representação em mesoescala do concreto, fundamentados em elementos finitos, modelos de redes e de partículas, foram desenvolvidos para investigar a influência da composição do material no comportamento geral, mecânico, de degradação ou combinado.

Rodrigues et al. (2016) destacam que o método de elementos finitos é amplamente utilizado devido à sua capacidade de representar explicitamente os elementos mesoscópicos que compõem o concreto. Esse recurso permitiu que autores, como Borges et al., (2017), desenvolvessem um modelo 2D de escala mesoscópica baseado no conceito de Elemento de Volume Representativo (EVR), considerando que o concreto é composto por três fases: zona de interface, matriz e inclusões. Os autores descreveram uma estratégia baseada na homogeneização computacional para caracterizar o comportamento mecânico de materiais frágeis, como o concreto, utilizando o MEF na análise em mesoescala.

Figura 5. Representação em mesoescala do concreto por discretização por elementos finitos.




Fonte: Traduzido de Koopas, Rauter e Lammering (2023).

Koopas, Rauter e Lammering (2023) avaliaram novas metodologias baseadas em elementos finitos para analisar o surgimento e a propagação de fissuras e fraturas em mesoestruturas de concreto altamente heterogêneas. Propondo algoritmos para gerar e classificar características geométricas na fase contínua, que representam a matriz de argamassa, agregados e vazios de diferentes tamanhos, distribuídos aleatoriamente (Figura 5). O estudo também investigou os efeitos dos tamanhos e das frações dos vazios no comportamento mecânico do concreto.

Rodrigues (2015) propôs um modelo de dano à tração para representar o comportamento mecânico não linear das diferentes interfaces, decorrente do surgimento ou do fechamento de fissuras em estruturas de concreto. Apresentando uma solução prática para superar o problema de transição entre as malhas de elementos finitos em modelos de macro e mesoescala, utilizando técnicas de acoplamento que permitem estabelecer a continuidade do deslocamento entre as malhas de forma independente, sem aumentar o grau de liberdade do sistema, facilitando o acoplamento de malhas sobrepostas ou não sobrepostas.

De forma análoga, Vieira (2021), explorou a possibilidade de representar o concreto por meio de malhas sobrepostas, utilizando a metodologia baseada no MEF, na versão Posicional (MEFP), em que a função de transformação do estado indeformado para o deformado é definida pelas posições nodais dos elementos finitos. Com isso, o autor verificou a possibilidade de representar diferentes fases do compósito de forma simplificada e com malhas independentes (considerando argamassa, agregado graúdo e fibras) (Figura 6), sem a necessidade de coincidência dos nós e sem adicionar novos graus de liberdade ao sistema. A metodologia de acoplamento de malhas foi utilizada para desenvolver um código computacional capaz de simular a propagação de fissuras em meios contínuos reforçados com partículas, com ênfase no concreto.

Figura 6. Sobreposição de malhas modelo mesoescala.



Fonte: Vieira (2021).


Silva (2020) desenvolveu uma metodologia numérica que combina o MEF com técnicas de Inteligência Artificial, aplicando conceitos da mecânica do dano computacional para analisar materiais compósitos cimentícios em uma abordagem multiescala. A criação de modelos equivalentes em macroescala foi realizada por meio de técnicas probabilísticas, com o apoio da inteligência artificial. Para os modelos em

mesoescala, foram exploradas duas abordagens distintas: na primeira, as fibras foram incorporadas por meio de elementos de interface, enquanto, na segunda, foram utilizadas como elementos compósitos de fibra e matriz. Em ambos os modelos, foram analisados o dano e a propagação de fissuras.

Rodrigues et al. (2016) observaram que modelos baseados em redes (conceito associado ao arranjo de redes geométricas interconectadas) podem ser utilizados para representar elementos de concreto em escala mesoscópica. Nesses modelos, os materiais são representados por um sistema discreto de elementos estruturais simples, como vigas e treliças. Nos modelos de treliça formados por elementos de vigas, as conexões entre os nós podem ser feitas utilizando vigas de Euler-Bernoulli ou de Timoshenko, especialmente quando os elementos da treliça são curtos (NIKOLIĆ et al., 2018).

De acordo com Thilakarathna et al. (2020), nas estruturas de rede podem ser encontrados diversos arranjos geométricos, como redes quadradas, redes triangulares e redes aleatórias, conforme mostra a Figura 7.

Figura 7. Arranjo geométrico de modelos com redes.




Fonte: Traduzido de Mungule e Raghuprasad (2011).

Considerando o modelo de Redes, Grassl e Jirásek (2010), realizaram análises numéricas de elementos de concreto em mesoescala para investigar a Zona de Processo de Fratura (FPZ) do concreto submetido à tensão uniaxial. A estrutura mesoscópica foi analisada considerando que o concreto estava composto por agregados rígidos inseridos em uma matriz mais macia, separados por interfaces frágeis. Para simular a resposta mecânica desses componentes, foram utilizadas redes discretas, nas quais a matriz, as inclusões e as interfaces são representadas por elementos de rede interconectados.

Vidya Sagar et al. (2019) também utilizaram um modelo de rede bidimensional, que foi comparado com medições de Emissão Acústica (EA) para investigar o processo de fratura em modo I em concreto simples submetido a ensaio de tração em três pontos. O estudo concentrou-se em modelos de mesoescala, sendo o concreto representado por uma rede triangular equilátera (treliça triangular regular), composta por elementos de vigas de Timoshenko (Figura 8), simulados com programas desenvolvidos em Matlab e Fortran. O estudo demonstrou uma forte correlação entre modelos de mesoescala e dados experimentais, destacando a eficácia dessas modelagens para prever o comportamento da fratura em materiais heterogêneos, como o concreto.

Figura 8. (a) Mapeamentos das propriedades dos membros da rede (agregado, matriz e ligação) e (b) Representação esquemática de um elemento de viga de dois nós.



Fonte: Traduzido de Vidya Sagar et al. (2019).


Mungule e Raghuprasad (2011) realizaram um estudo para identificar como os parâmetros dos materiais e das estruturas (fração volumétrica de agregado, espessura e profundidade) influenciam o comportamento global do concreto. A metodologia baseou-se em simulações numéricas discretas, nas quais a modelagem de rede foi empregada para analisar o impacto dos agregados na formação de microfissuras e na capacidade de absorção de energia da matéria em modelos de mesoescala. Os resultados demonstraram que essa abordagem é eficaz para capturar a interação entre os agregados e a matriz de cimento, destacando que a heterogeneidade do concreto afeta significativamente a resistência e a capacidade de absorção de energia.

Schlangen e Van Mier, (1992) investigaram o comportamento de fratura em concreto e argamassa em modelos heterogêneos em mesoescala, com foco no endurecimento por meio de um mecanismo denominado ponte de face de fissura. Os mecanismos de falha foram simulados por meio de modelagem numérica de redes, na qual foi gerada a estrutura granular do material, sobre a qual foi aplicada uma rede triangular de elementos de viga com falha frágil para simular o crescimento de fissuras. A matriz, os agregados e as interfaces foram representados por elementos interconectados em rede, capturando a resposta mecânica dos componentes. Os resultados permitiram inferir que as pontes de face de fissura, formadas por ligamentos flexurais entre pontas de fissura sobrepostas, desempenham um papel crucial na fratura controlada, e que o estresse coesivo na microfissura está diretamente relacionado ao tamanho dessas pontes, que depende da heterogeneidade do material.

Jivkov et al. (2013) desenvolveram um modelo de rede em mesoescala para estudar a relação entre a porosidade e a evolução do dano frágil no concreto. A porosidade do concreto foi determinada experimentalmente por meio de tomografia computadorizada de raios-X (X-ray CT), gerando um modelo tridimensional da distribuição e conectividade dos poros. Essa distribuição de tamanhos de poros foi atribuída aos vínculos da malha do modelo, que representam a microestrutura do concreto. A Figura 9 ilustra o modelo de rede e o tipo de célula unitária usados no modelo, que consistiu em um octaedro truncado, um sólido com seis faces quadradas e oito faces hexagonais regulares. A configuração 3D do modelo foi definida com base em células que representaram cada uma das características dos materiais do modelo em mesoescala. O modelo proposto conseguiu prever com precisão significativa o comportamento do concreto em níveis de tensão mais baixos, ao comparar os resultados simulados com os obtidos em experimentos.

Outras abordagens para a representação do concreto em mesoescala, utilizam análises baseadas em modelos de partículas. Nesses modelos, o material é representado por partículas rígidas conectadas aos seus vizinhos por elementos de viga ou molas, numericamente semelhantes aos modelos de rede. Embora esse método seja computacionalmente mais eficiente do que o de redes, a complexidade das configurações que descrevem as interações entre as partículas é maior (RODRIGUES *et al.*, 2016).

Figura 9. (a) Célula unitária e (b) rede discreta de elemento de viga.



Fonte: Jivkov et al. (2013).

Um dos métodos de partículas mais utilizados para analisar o comportamento mesoscópico de materiais granulares, como o concreto, é o Método de Elementos Discretos (DEM). Nesse método, o equilíbrio das forças e dos deslocamentos de um conjunto de partículas discretas é determinado ao se acompanhar o movimento dessas partículas. Geometricamente, essas partículas podem ser representadas por formas arredondadas, em análises 2D, ou esféricas, em análises 3D (YU; ZHENG; ZHAO, 2021).


Um estudo de caso usando partículas em simulação bidimensional foi desenvolvido por Kim, Wagoner e Buttlar (2009) para investigar o comportamento de fraturas em concreto asfáltico, utilizando um modelo em mesoescala com DEM para capturar a heterogeneidade do material. O estudo se concentrou na simulação de fissuras em uma viga entalhada de borda única (Figura 10) e na análise de seu comportamento sob modos de fratura I e misto.

A abordagem DEM incorporou a agregação de partículas discretas e o mástique asfalto-agregado, permitindo uma representação detalhada das interações entre os componentes. Os resultados demonstraram que o modelo numérico de fratura com amortecimento coesivo, utilizado como lei constitutiva, foi capaz de prever de forma satisfatória a propagação das fissuras, tanto no modo I quanto no modo misto.

Por outro lado Knak, Nitka e Rucka (2024), analisaram a propagação de ondas ultrassônicas no concreto utilizando um modelo cúbico com dimensões de 50x50x50 mm (Figura 11). O objetivo foi capturar a resposta do concreto sob ondas e comparar os resultados numéricos com dados experimentais. No modelo de mesoescala, foram consideradas as características heterogêneas do concreto, especialmente os


agregados e as zonas de porosidade. O método utilizado concentrou-se no emprego de microparâmetros locais das partículas no modelo DEM, garantindo que a resposta global da amostra de concreto estivesse em concordância com os valores experimentais. Ao final, o modelo foi capaz de prever a propagação das ondas, captando sua influência sobre a estrutura interna do material.

Figura 10. Geometria e malha do modelo de fratura DEM no modo I.



Fonte: Traduzido de Kim, Wagoner, Buttlar (2009).

Figura 11. a) Modelo experimental-cubo de concreto e b) Modelos numérico DEM.



Fonte: Traduzido de Knak, Nitka e Rucka (2024).

2.3 CARACTERIZAÇÃO E DISCRETIZAÇÃO DO COMPÓSITO

Dentre os métodos mencionados anteriormente, o método dos elementos finitos é o mais utilizado para representar o concreto em mesoescala (EMERY et al., 2007). Um dos principais desafios desse método é a representação e a discretização dos diferentes componentes do concreto, como a matriz de argamassa, os agregados e os vazios.

A matriz de argamassa nos modelos em mesoescala é geralmente representada por uma fase contínua que envolve os agregados, sendo muito importante para simular com fidelidade o comportamento mecânico do material (VAN MIER, 1996).

De acordo com Santos (2022), a matriz de argamassa é geralmente modelada como uma fase homogênea que preenche o espaço entre os agregados no concreto. Para representar adequadamente essa matriz, é comum utilizar técnicas de geração aleatória de agregados, assegurando que não haja sobreposição entre as fases e permitindo uma distribuição realista dos agregados na matriz.

Na análise via MEF, a matriz de argamassa é discretizada em elementos que podem variar conforme a complexidade do modelo e os recursos computacionais disponíveis.

A escolha do tipo de elemento (por exemplo, triangular ou quadrilátero) e o refinamento da malha afetam a precisão dos resultados e a eficiência computacional. A utilização de elementos triangulares é comum devido à sua flexibilidade na adaptação a geometrias complexas e à capacidade de modelar de forma precisa as zonas de transição e entre diferentes fases do concreto (GODOI, 2016).


Por esse motivo, diversos trabalhos optaram por utilizar uma malha de elementos triangulares para representar a matriz de argamassa (RODRIGUES et al. 2016; KOOPAS; RAUTER; LAMMERING, 2023; BORGES et al., 2017; GIMENES et al., 2023; VIEIRA, 2021).

Em relação aos agregados, sua representação desempenha papel fundamental no desenvolvimento de modelos de concreto em mesoescala, uma vez que sua forma influencia diversas propriedades do material, como a resistência mecânica, as características de dano e os processos de fratura (MURSHIDA; JIYAD; NAGARAJAN, 2023). De acordo com Thilakarathna et al. (2020) as formas mais comumente utilizadas para representar agregados em 2D são polígonos, círculos e elipses, enquanto em 3D são esferas, elipsoides e poliedros.

Nesse contexto, Gimenes et al. (2023), realizaram modelagens bidimensionais, em mesoescala, para analisar a fratura sob ação de forças compressivas, optando por representar os agregados graúdos como polígonos octogonais regulares. Essa escolha se deve à simplicidade geométrica dos octógonos e à eficácia previamente demonstrada em estudos na literatura. Os polígonos foram distribuídos na matriz de argamassa por meio da técnica "*take-and-place*", que

consiste em um processo iterativo de posicionamento sequencial das partículas, começando pelas maiores e seguindo até as menores. Duas restrições geométricas principais foram aplicadas: a distância mínima entre agregados, proporcional ao tamanho de cada partícula, e a distância mínima entre os agregados e as bordas do domínio. A faixa de tamanhos das partículas foi definida com base em uma curva granulométrica, obtida experimentalmente ou teoricamente, garantindo o atingimento da fração volumétrica especificada de agregados. Essa abordagem assegurou uma representação com maior fidelidade dos agregados e contribuiu para a precisão obtida nas modelagens, representando essa, apresentada na Figura 12.

Figura 12. Modelagem com agregados em forma poligonal.




Fonte: Traduzido de Gimenes et al. (2023).

Nguyen et al. (2010) conduziram um estudo sobre elementos de volume representativos (RVE) para a modelagem multiescala baseada na homogeneização de materiais amolecidos, utilizando agregados representados por formas circulares, com tamanhos variando de 2,5 mm a 5,0 mm, distribuídos aleatoriamente no domínio, como ilustrado na Figura 13. A geração dos agregados foi realizada com o auxílio do software SPACE, considerando parâmetros como a fração volumétrica (30%, 40% e 60%), a distribuição de tamanhos e a densidade dos agregados. Além disso, cada agregado foi circundado por uma zona de transição interfacial (ITZ) com largura fixa de 0,25 mm, que representa a interação entre os agregados e a matriz. A metodologia

incluiu a discretização das amostras geradas em malhas de elementos finitos, compostas por elementos triangulares de três nós (ordem de aproximação linear), permitindo a simulação de tensões e deformações em microescala.


Figura 13. Malha com representação trifásica do material.



Fonte: Traduzido de Nguyen et al. (2010)

Wang e Jivkov (2015) conduziram diversos estudos sobre modelos de concreto em mesoescala, abrangendo tanto representações em 2D quanto em 3D. Nos modelos bidimensionais, os agregados foram representados por formas elípticas ou poligonais, enquanto nos tridimensionais, assumiram geometrias elipsoidais ou poliédricas. Além disso, os vazios foram incorporados ao modelo, sendo representados por formas circulares ou elípticas no caso dos modelos 2D e, esféricas ou elipsoidais, nos modelos 3D (Figura 14). Os modelos foram gerados por meio de algoritmos baseados no método de Monte Carlo, considerando distribuições predefinidas de tamanho, forma e fração volumétrica dos componentes. O processo de geração seguiu uma sequência automatizada que incluía a definição de parâmetros de controle, a geração e o posicionamento de vazios e agregados em uma área ou volume predefinido, garantindo a ausência de sobreposição ou interseção entre as inclusões. As malhas foram desenvolvidas no ANSYS e as simulações não lineares foram conduzidas no ABAQUS.


Figura 14. Modelo: a) agregados elípticos 2D e vazios circulares; b) agregados elipsoidais 3D e vazios esféricos.



Fonte: Wang e Jivkov (2015).

No modelo tridimensional de concreto em mesoescala desenvolvido por Zhou, Song e Lu (2017), os agregados graúdos foram representados geometricamente como poliedros irregulares (Figura 15). Segundo os autores, essa abordagem oferece maior precisão na representação das formas reais dos grãos utilizados em concretos de engenharia, superando as limitações das representações simplificadas, como esferas ou elipsoides. Para gerar essas formas poliédricas, foi aplicado um algoritmo computacional baseado em distribuições granulométricas reais obtidas experimentalmente. Esse algoritmo possibilitou a criação de agregados com tamanhos e formas variados, respeitando os limites granulométricos e garantindo uma distribuição espacial aleatória na matriz de argamassa discretizada por elementos finitos refinados, o que permitiu determinar com maior precisão os detalhes das tensões e deformações. Por sua vez, os agregados foram integrados ao modelo como inclusões rígidas com tamanhos e formatos diversos. A integração entre os agregados e a matriz foi realizada por meio de uma técnica de acoplamento geométrico, que assegurou a continuidade entre os domínios e aprimorou a representatividade do modelo tridimensional.

Figura 15. Estrutura 3D dos agregados em mesoescala e visualização do compósito em corte.




Fonte: Zhou, Song e Lu (2017).

Além da forma dos agregados, as suas dimensões têm efeitos significativos na evolução das fissuras no concreto. De acordo com Yu, Qing e Hu (2025), o tamanho dos agregados influencia diretamente na propagação de fissuras e no comportamento mecânico do material, impactando a formação e o desenvolvimento da zona de processo de fratura. Estudos em modelos de mesoescala têm investigado esses efeitos, variando as dimensões dos agregados e demonstrando que o tamanho dos mesmos é uma característica fundamental que deve ser analisada em modelos de concreto para uma representação mais precisa do seu comportamento mecânico.

Dessa forma, Zheng et al. (2023), apresentam um estudo sobre a modelagem em mesoescala do concreto utilizando o MEF, com o objetivo de investigar como as características dos agregados, incluindo tamanho e forma, influenciam a resistência à compressão do concreto.

No modelo desenvolvido, os agregados foram classificados em faixas granulométricas, baseadas na curva de Fuller, que visa maximizar a compactidade do concreto, e representados por tamanhos equivalentes. Na faixa de 5–20 mm, adotou-se um tamanho uniforme de 13 mm, enquanto na faixa de 20–40 mm, foram simulados agregados com dimensões de 20, 25, 30, 35 e 40 mm (Figura 16.a). Além disso, diferentes formas de agregados foram consideradas: circulares, para representar materiais arredondados, como seixos; elípticas, que se aproximam de formas alongadas comuns em materiais erosivos; e poligonais, para representar materiais angulares, como britas (Figura 16.b).


Figura 16. a) Diâmetros dos agregados e b) forma dos agregados discretizados.



Fonte: Traduzido de Zheng et al. (2023).

Zhou, Jin e Wang, (2019), também realizaram modelagens em mesoescala baseadas no MEF para investigar o impacto das formas e tamanhos reais dos agregados no comportamento mecânico do concreto, com ênfase na resistência à compressão. Para esses modelos, foi criado um banco de dados com 1568 partículas 2D obtidas a partir de cortes aleatórios de agregados tridimensionais reais, escaneados a laser com alta precisão. Os agregados selecionados tinham diferentes tamanhos (16 mm, 12 mm e 8 mm) e foram organizados em modelos cúbicos (150 mm x 150 mm) para simulações de compressão uniaxial (Figura 17).

Figura 17. Diâmetro dos agregados utilizados no modelo mesoescala.




Fonte: Traduzido de Zhou, Jin e Wang (2019).

As formas reais dos agregados foram avaliadas com base em três parâmetros principais: alongamento, circularidade e rugosidade, que descrevem características como alongamento, arredondamento e textura superficial. As simulações foram realizadas no software ABAQUS, no qual os modelos foram submetidos a condições de carga incremental em compressão uniaxial, permitindo avaliar com precisão significativa o comportamento do concreto.

Por outro lado, Jin et al. (2020) conduziram estudos para avaliar os efeitos da variação dos tamanhos e da quantidade de agregados máximos em modelos de mesoescala, analisando o comportamento mecânico do concreto, com foco na resistência à tração por compressão diametral. Nas modelagens, os tamanhos dos agregados foram classificados em três faixas granulométricas distintas: 5–20 mm, representados por agregados equivalentes de 8 mm e 15 mm; 5–30 mm, representados por agregados equivalentes de 15 mm e 25 mm; e 5–40 mm, representados por agregados equivalentes de 25 mm e 32 mm (Figura 18). Para gerar a distribuição dos agregados nos modelos, utilizou-se o método de Monte Carlo, o que permite a alocação aleatória das partículas no concreto. As análises foram realizadas no software ABAQUS, empregando elementos finitos tridimensionais e malhas com tamanho de 2 mm. Modelos cúbicos de diferentes dimensões (150 mm, 300 mm e 450 mm) foram submetidos a condições de compressão diametral dinâmica, com aplicação de cargas incrementais controladas pela velocidade.

Figura 18. Modelos cúbicos em mesoescala com diferentes dimensões e tamanhos de agregados equivalentes.



Fonte: Jin et al. (2020).

Conforme destacado anteriormente, o concreto em mesoescala é constituído principalmente por duas fases: a matriz de argamassa e os agregados, podendo incluir uma terceira fase intermediária, situada entre elas, conhecida como zona de transição interfacial (HÄFNER et al., 2006). De forma semelhante, Shahbazi; Rasoolan (2017), descrevem que o concreto em mesoescala pode ser considerado como um material trifásico não homogêneo, constituído por três principais componentes: a pasta de cimento, os agregados (que podem variar em tamanho e geometria) e uma última fase correspondente a uma zona de transição interna.

Segundo Maleki et al. (2020) a zona de transição interfacial ou interna é gerada durante o processo de hidratação do cimento devido à diferença de tamanho entre os grãos de cimento anidro, que variam de menos de um micrômetro a 100 μm , e as partículas de agregado, que são significativamente maiores. Essa diferença faz com que os agregados atuem como barreiras físicas, dificultando a deposição uniforme dos grãos de cimento e criando o chamado "efeito parede". Como consequência, a pasta de cimento densa é deslocada para longe dos agregados, enquanto uma camada mais porosa se forma ao seu redor. Além disso, o fenômeno de exsudação local, caracterizado pelo acúmulo de água sob as partículas de agregado, contribui para a segregação dos grãos de cimento nessa região, resultando em uma zona de transição interfacial com menor densidade e resistência em comparação com a matriz de argamassa.

Definindo, então, as zonas de transição interfacial, como camadas estreitas que envolvem os agregados, promovendo a adesão à matriz de cimento. No entanto, essas regiões apresentam maior porosidade e diferenças microestruturais significativas em relação à matriz, tornando-se os pontos mais frágeis do concreto. Essas características impactam diretamente com o comportamento de fratura do material, influenciando na propagação de fissuras e a resistência mecânica geral (LYU et al., 2019).

Portanto, sua inclusão no modelo em mesoescala é essencial. No entanto, conforme Rodrigues et al. (2016) a representação dessas camadas é um dos maiores desafios na elaboração da malha de elementos finitos. Dessa forma, é fundamental adotar uma estratégia adequada para sua implementação, considerando a grande influência que essas camadas exercem sobre o modelo, especialmente na região de iniciação de fissuras.

Nas simulações em mesoescala, os vazios podem ser representados de duas maneiras distintas. Em modelos bifásicos (argamassa + agregados), é comum a representação indireta dos vazios por meio da degradação localizada da matriz de argamassa. Essa abordagem busca capturar, de forma simplificada, os efeitos da porosidade intrínseca do concreto, sem a necessidade de identificar explicitamente cada vazio. Já em modelos trifásicos (argamassa + agregados + vazios), os vazios são representados de forma explícita como regiões geométricas distintas dentro do domínio, exigindo maior detalhamento na geração da malha e no controle da distribuição espacial dos poros.

Contudo, uma das principais limitações na modelagem em mesoescala com os vazios está na dificuldade de determinar, a priori, o seu teor e distribuição no compósito. Em geral, esse conhecimento só é possível por meio de ensaios laboratoriais específicos, como a tomografia computadorizada ou testes de porosidade. Quando a modelagem é realizada com base apenas nas proporções e propriedades dos materiais constituintes, torna-se necessário estimar parâmetros representativos dos vazios. Essa estimativa pode ser feita com base em dados experimentais da literatura ou por meio de técnicas de homogeneização e otimização, garantindo que a representação mesoscópica seja condizente com o comportamento real do concreto.

2.4 DEFINIÇÃO DO ÍNDICE DE VAZIOS – POROSIDADE DO CONCRETO

As pesquisas que tratam da predição da porosidade do concreto atualmente seguem duas abordagens principais. A primeira utiliza modelos físicos tradicionais, nos quais a porosidade é analisada por meio das reações de hidratação ou da avaliação do grau de compactação do material. Embora esses modelos ofereçam precisão devido à consideração detalhada das propriedades físicas dos materiais, apresentam grande dificuldade no processamento de dados. Na segunda abordagem, empregam-se técnicas de processamento de dados baseadas em algoritmos de Aprendizado de Máquina. Essas técnicas permitem previsões sem compreender todo o fenômeno e a correlação entre todos os parâmetros envolvidos (GONG et al., 2024).

2.4.1 Formulações analíticas

A predição das propriedades do concreto, como a porosidade, pode ser realizada por meio de diversas metodologias analíticas. Uma abordagem comum é o uso de modelos empíricos que correlacionam dados experimentais às propriedades desejadas.

Khan e Asce (2003), realizaram estudos para a predição empírica das propriedades de permeação do concreto, utilizando modelos matemáticos desenvolvidos com base em experimentos laboratoriais. Os autores trabalharam com misturas de concreto com diferentes relações água-aglomerante (0,27, 0,40 e 0,50), considerando a incorporação de cinzas volantes e microssílicas como materiais cimentícios suplementares. Os corpos de prova foram submetidos a três condições distintas de cura (úmida, ao ar livre e temperatura controlada de 5°C), com o objetivo de avaliar a influência das condições ambientais nas propriedades de permeação.

Para determinar a permeabilidade ao oxigênio, utilizou-se um permeâmetro de gás, enquanto a sorptividade foi avaliada por meio de um ensaio de absorção capilar, que mensura a relação entre o volume de água absorvido e o tempo. Já a porosidade em porcentagem (p), foi determinada pelo método de saturação a vácuo-pressão, utilizando a Equação 10.

$$p = \frac{B - A}{B - C} * 100 \quad \text{Equação 10}$$

onde (A) é o peso seco ao forno, (B) é o peso saturado em superfície seca e (C) é o peso saturado submerso.

Os resultados indicaram que a incorporação de microssílica reduz significativamente a porosidade do concreto, enquanto a cinza volante apresenta um efeito mais discreto.

Já o estudo de Nehme, (2000) apresenta um método analítico para calcular a porosidade do concreto, considerando tanto o estado fresco quanto o endurecido. A porosidade do concreto fresco depende de fatores como a saturação, o teor de ar incorporado, a qualidade dos agregados e a compactação do material. A Equação 11, define a formulação geral para a porosidade inicial (p_0) do concreto no estado fresco.

$$p_0 = 1 - \frac{V}{V_T} = 1 - \frac{\frac{m_c}{\rho_c} + \frac{m_w}{\rho_w} + \frac{m_a}{\rho_a}}{m_c + m_w + m_a} * \rho_t \quad \text{Equação 11}$$

onde (V_T) é o volume total do concreto, (V) é o volume compacto, (m_c, m_w, m_a) são as massas de cimento, água e agregados, respectivamente, e (ρ_c, ρ_w, ρ_a) são suas correspondentes densidades, e (ρ_t) é a densidade real do concreto no estado fresco.

Além dos fatores mencionados anteriormente, a porosidade do concreto endurecido também é influenciada pela relação água-cimento (teor elevado de água), pelo grau de hidratação (idade do concreto) e pela retração do material. Dessa forma, a porosidade (p) do concreto totalmente hidratado é definida pela Equação 12.

$$p = 1 - \frac{V}{V_T} = 1 - \frac{\left(\frac{m_c}{\rho_c} + \frac{0.342 + m_w}{\rho_w} + \frac{m_a}{\rho_a}\right)}{m_c + m_w + m_a} * \rho_t \quad \text{Equação 12}$$

Caso a retração do concreto seja igual a zero, a Equação 12 pode ser reescrita pela Equação 13.

$$p = 1 - \frac{\frac{1}{\rho_c} + \frac{0.342}{\rho_w} + \frac{y}{\rho_a}}{1 + x + y} * \rho_t \quad \text{Equação 13}$$

em que (x) a relação água-cimento e (y) a relação agregado-cimento.

Se a porosidade inicial for igual a zero e a retração também, a porosidade do concreto pode ser expressa pela Equação 14 e no caso que a porosidade inicial e a retração não sejam nulas, e o concreto esteja totalmente hidratado, a porosidade pode ser calcula pela Equação 15.

$$p = 1 - \frac{\frac{1}{\rho_c} + \frac{0.342}{\rho_w} + \frac{y}{\rho_a}}{\frac{1}{\rho_c} + \frac{x}{\rho_w} + \frac{y}{\rho_a}} \quad \text{Equação 14}$$

$$p = 1 - \frac{2.06 * V_c + V_A}{V_T} = 1 - \frac{\frac{2.06}{\rho_c} + \frac{y}{\rho_a}}{y + 1.342} * \rho_b \quad \text{Equação 15}$$

em que (V_c) é o volume de cimento, (V_A) o volume do agregado, (V_T) o volume do corpo de concreto endurecido e (ρ_b) a densidade do concreto endurecido.

Das Equações 14 e 15, percebe-se que a relação água/cimento influencia diretamente a porosidade do concreto ao longo do tempo. Quando essa relação é inferior a 0,342, a porosidade do concreto fresco tende a ser superior à do concreto endurecido. Caso seja exatamente 0,342, ambas permanecem equivalentes. No

entanto, se o valor for superior a 0,342, a hidratação total resulta em aumento da porosidade no estado endurecido, como ocorre no concreto fresco. Considerando o efeito do grau das hidratação (α), a porosidade pode ser determinada pela Equação 16.

$$p = \frac{V_W + V_L + V_C - V_{CK}}{V_T} = 1 - \frac{V_A + (1 + 1.06 * \alpha) * V_C}{V_T} \quad \text{Equação 16}$$

em que (V_W) é o volume de água, (V_C) volume de cimento, (V_{CK}) volume de cimento dependendo do grau de hidratação, (V_A) volume de agregado, (V_T) volume de concreto fresco e (V_L) teor de ar real do concreto fresco.

2.4.2 Modelos baseados em Aprendizado de Máquina

Com o avanço do Aprendizado de Máquina e da Ciência de Dados, os modelos preditivos baseados em dados têm se destacado na Ciência dos Materiais, permitindo a análise e extração de conhecimento a partir de grandes volumes de dados experimentais e computacionais. Essas abordagens facilitam a descoberta de novos materiais e possibilitam a avaliação do comportamento de diversas propriedades, contribuindo para um entendimento mais aprofundado de suas características (SCHLEDER; FAZZIO, 2021).

Segundo Ludemir (2021) existem três tipos principais de Aprendizado de Máquina: supervisionado, não supervisionado e por reforço. De acordo com Batista (2019), no aprendizado supervisionado, o algoritmo recebe um conjunto de exemplos rotulados, no qual as respostas corretas já são definidas. Esse conjunto, conhecido como conjunto de treinamento, permite que o modelo identifique padrões e desenvolva a capacidade de generalizar, tornando-o apto a prever corretamente novas entradas no futuro.

Ferreira (2023) apresenta um listado dos algoritmos de Aprendizado de Máquina supervisionados mais empregados na Ciência de Dados:

- k-Nearest Neighbours (k-vizinhos mais próximos);
- Linear Regression (Regressão linear);
- Logistic Regression (Regressão Logística);
- Support Vectors Machine (Máquinas de Vetores de Suporte - SVMs);

- Decision Trees (Árvores de Decisão) e Random Forest (Florestas Aleatórias);
- Neural Networks (Redes neurais).

No caso do aprendizado não supervisionado, os exemplos fornecidos ao algoritmo não possuem rótulos. O modelo analisa os dados e identifica padrões ou semelhanças entre os atributos, organizando-os em agrupamentos (clusters). Após essa etapa, geralmente é necessária uma análise para interpretar o significado de cada grupo no contexto do problema estudado (LUDERMIR, 2021).

Na Tabela 1 são apresentados alguns dos algoritmos de aprendizado não supervisionados apontados por Ferreira (2023), como os mais empregados.

Tabela 1 . Algoritmos de Aprendizado de Máquina não supervisionado.

Agrupamento	Visualização e redução de dimensionalidade	Aprendizagem de regra de associação
k-Means	Análise de Componentes Principais (PCA)	A priori
Análise Hierárquica de Cluster (HCA)	Núcleo PCA	Eclat
Maximização da Expectativa	Incorporação Localmente Linear (LLE)	
	Incorporação de vizinhos estocásticos distribuídos em t (t-SNE)	

Fonte: Modificado de Ferreira (2023).

Pack et al. (1996) definem que o aprendizado por reforço é um processo no qual um agente aprende a tomar decisões interagindo com um ambiente dinâmico por meio de tentativa e erro. Diferentemente do aprendizado supervisionado, em que há uma correspondência pré-definida entre entradas e saídas, no aprendizado por reforço o agente recebe recompensas ou penalidades com base em suas ações, sem orientações explícitas sobre qual decisão seria a melhor a longo prazo.

Dentro desse contexto, Félix (2022) explora os diferentes algoritmos de aprendizado por reforço, organizando-os em categorias conforme o aspecto do aprendizado que buscam aprimorar. Entre os principais algoritmos mencionados pelo autor, destacam-se:

- Aprendizado da Política;
- Aprendizado da Função de Valor;
- Aprendizado do Modelo;
- Ator-Crítico;
- Estratégia Híbrida.


Seguindo as metodologias apresentadas anteriormente, Cao (2023) , desenvolveram modelos de Aprendizado de Máquina para prever a porosidade do concreto, considerando variações na composição da mistura e nas condições de cura. Para isso, foram empregadas técnicas de Aprendizado de Máquina supervisionado, nas quais o modelo aprende a partir de um conjunto de dados rotulado, ou seja, com entradas definidas (parâmetros da mistura) e saídas conhecidas (valores de porosidade).

Dentre os modelos testados, destacam-se algoritmos baseados em árvores de decisão, como florestas aleatórias (Random Forests) e Gradient Boosting Trees (GBT). O modelo XGBoost foi selecionado como o mais eficiente, apresentando os melhores resultados. Especificamente, o XGBoost obteve um coeficiente de determinação R^2 de 0.9770, um erro absoluto percentual médio (MAPE) de 2,97% e um erro quadrático médio (RMSE) de 0,431, superando os outros modelos avaliados. Em comparação, o Random Forests apresentou um R^2 médio de 0.901, MAPE de 5,77% e RMSE de 0.89, enquanto o GBT alcançou R^2 de 0.942, MAPE de 4,66% e RMSE de 0.68.

A base de dados utilizada continha 240 registros experimentais de porosidade do concreto, distribuídos em 74 composições diferentes. Conforme ilustrado na Figura 19, a metodologia aplicada no Random Forest combina múltiplas árvores de decisão, reduzindo a variabilidade das previsões e aumentando a robustez do modelo. Apesar dessa estabilidade, o Random Forest pode não alcançar a mesma precisão que métodos mais sofisticados, especialmente em conjuntos de dados mais complexos.

Uma alternativa mais precisa é o Gradient Boosting Trees (GBT), que difere do Random Forests por construir suas árvores de forma sequencial. Nesse método, cada nova árvore aprende com os erros das anteriores, refinando progressivamente as previsões. Esse processo tende a melhorar a capacidade preditiva do modelo, mas também pode torná-lo mais suscetível ao overfitting se não for adequadamente regulado (SUGASAWA; NOMA, 2019).

Figura 19. Arquitetura de árvores de decisão.



Fonte: Traduzido de Cao (2023).

Para mitigar esse problema e aumentar a eficiência computacional, surge o XGBoost, uma versão otimizada do GBT. Segundo Wiens et al. (2025), o XGBoost incorpora técnicas avançadas, como regularização L1 e L2, paralelização do treinamento e poda de árvores, permitindo um melhor controle da complexidade do modelo. Essas melhorias fazem com que o XGBoost se destaque como um dos modelos mais eficientes em Aprendizado de Máquina, proporcionando previsões mais precisas e tempos de processamento reduzidos em comparação com os demais algoritmos baseados em árvores de decisão.


Na mesma linha, Gong et al. (2024) analisaram a evolução da porosidade interna do concreto exposto ao ataque de sulfato e desenvolveram modelos de Aprendizado de Máquina para prever essas variações. Para isso, realizaram ensaios de envelhecimento acelerado em amostras retiradas de um túnel, submetendo-as a soluções de sulfato por 60, 120 e 180 dias. A tomografia computadorizada (CT-scan) foi utilizada para capturar as mudanças na porosidade, e os dados foram processados por meio de algoritmos de aprendizado supervisionado, incluindo Random Forest (RF), Gradient Boosting Decision Tree (GBDT), XGBoost e LightGBM. O objetivo foi prever a porosidade futura com base em imagens de baixa resolução, reduzindo a necessidade de ensaios mais complexos.

Os resultados indicaram que o modelo Random Forest apresentou a melhor precisão, com um R^2 de 0.998 e um erro quadrático médio (RMSE) inferior a 0.0002 para um conjunto de treinamento reduzido. O XGBoost e o GBDT também demonstraram boa capacidade preditiva, com R^2 entre 0.956 e 0.976 para conjuntos de treinamento menores. No entanto, o desempenho do LightGBM apresentou uma queda acentuada na precisão conforme o tamanho do conjunto de treinamento foi

reduzido, atingindo um R^2 de apenas 0.491 no maior intervalo de amostragem.

A Figura 20 apresenta a comparação do desempenho realizada pelo autor dos quatro modelos por meio do diagrama de Taylor. O gráfico evidencia que o Random Forest manteve um desempenho mais estável e preciso em diferentes configurações, enquanto os demais modelos apresentaram maior variabilidade em função da quantidade de dados disponíveis. Dessa forma, a escolha do modelo ideal depende da disponibilidade de dados e da necessidade de um equilíbrio entre precisão e eficiência computacional.

Figura 20. Diagrama de Taylor para comparação de performance.




Fonte: Traduzido de Gong et al. (2024).

Le et al. (2022) também realizaram estudos utilizando métodos de Aprendizado de Máquina para prever a porosidade efetiva e a resistência à compressão do concreto permeável, reconhecendo que a determinação experimental dessas propriedades é um processo demorado e complexo. Para superar essa limitação, os autores propuseram um modelo preditivo baseado em Aprendizado de Máquina. A metodologia envolveu a coleta de 164 amostras de diferentes fontes da literatura, com sete características principais da mistura, incluindo a razão agregado/cimento, a relação água/cimento, o tamanho mínimo do agregado graúdo e a presença de areia ou sílica ativa, além das variáveis de saída: porosidade efetiva e resistência à compressão.

Para realizar os mapeamentos, foram avaliados vários métodos de Aprendizado de Máquina: Extreme Gradient Boosting (XGB), Random Forest Regression (RFR) e Support Vector Machine (SVM), além do uso de Redes Neurais Artificiais (RNA) como abordagem adicional para modelagem preditiva. A Figura 21 ilustra a arquitetura da Rede Neural Artificial utilizada no estudo, destacando a presença de uma camada oculta com 512 neurônios, definida para melhorar a capacidade do modelo de captar padrões complexos nos dados.

Figura 21. Arquitetura da rede neural escolhida.



Fonte: Traduzido de Le et al. (2022).

Os resultados mostraram que o modelo XGB apresentou o melhor desempenho geral, com um coeficiente de determinação (R^2) de 0.93 e um erro quadrático médio (RMSE) de 1.25 MPa para a previsão da resistência à compressão. O modelo RFR obteve um desempenho semelhante, com R^2 de 0.91 e RMSE de 1.38 MPa, enquanto o SVM apresentou um desempenho inferior, com R^2 de 0.87 e RMSE de 1.62 MPa. A abordagem baseada em Redes Neurais Artificiais, por sua vez, demonstrou potencial para capturar padrões complexos, alcançando um R^2 de 0.92 e RMSE de 1.30 MPa, ficando próxima do desempenho do XGB.

Por outro lado, os estudos conduzidos por Santos et al. (2024), buscaram prever o índice de vazios (porosidade) em concretos com Resíduos de Construção e Demolição (RCD) por meio de técnicas de Aprendizado de Máquina. Para o desenvolvimento do modelo preditivo, os autores coletaram 154 conjuntos de dados


experimentais da literatura, que foram analisados e submetidos a um processo de pré-tratamento. O estudo considerou variáveis como o tipo e a quantidade de cimento, a proporção agregado/cimento, o teor de substituição do agregado graúdo por RCD e a relação água/aglomerante. Com base nesses dados, foram treinados dois modelos de Aprendizado de Máquina: Florestas Aleatórias e Redes Neurais Artificiais (RNA).

O modelo baseado em Floresta Aleatória demonstrou um desempenho promissor, com coeficiente de determinação (R^2) médio de 0,962 na etapa de treinamento, 0,882 nos testes e 0,944 na avaliação geral, o que indica um bom desempenho de aprendizado. No entanto, o estudo apontou uma tendência a um menor nível de generalização, sugerindo que um volume maior de dados poderia ser necessário para reduzir os riscos de ajuste e aumentar a confiabilidade dos resultados.

Já as Redes Neurais Artificiais (RNA) se destacaram por sua estabilidade e capacidade de generalização superiores. A configuração mais eficiente identificada foi a [6-6-6-1], que alcançou um R^2 ponderado de 0,933 e um erro quadrático médio (RMSE) de 1,5%, além de apresentar resíduos com distribuição normal.

A Figura 22 ilustra a arquitetura da RNA utilizada pelos autores, composta por duas camadas ocultas, cada uma com um máximo de 10 neurônios, totalizando 100 redes neurais. Além disso, uma análise da influência das variáveis de entrada destacou que fatores como o tipo de cimento, a quantidade de agregados e o nível de substituição por RCD desempenham papel fundamental na predição da porosidade do concreto.

Figura 22. Modelo de arquitetura da rede neural escolhida.



Fonte: Santos et al. (2024).

Paralelamente à modelagem computacional, foi realizada uma campanha


experimental para validar as previsões. Para isso, foram moldados concretos com diferentes níveis de substituição de agregados naturais por RCD (0%, 25%, 50%, 75% e 100%), mantendo-se constante a relação água/aglomerante. Os resultados experimentais, confrontados com os obtidos pelo modelo baseado em RNAs, demonstraram que o modelo é eficaz na predição do índice de vazios, com erro percentual absoluto máximo de 16%.

De forma semelhante, Nehme (2000) analisou a porosidade do concreto e sua previsão utilizando RNAs, onde os resultados mostraram que a porosidade é um fator determinante para a durabilidade e resistência do concreto, o autor empregou modelos computacionais para estimar sua relação com variáveis-chave, como relação água/cimento, grau de hidratação, teor de cimento, teor de ar do concreto fresco, diâmetro máximo do agregado e módulo de finura. A pesquisa utilizou um RNA multicamada para modelar a relação não linear entre esses fatores e a porosidade. O modelo adotado foi uma rede neural feedforward, estruturada com uma camada oculta composta por 10 neurônios, com função de ativação sigmoide, e uma camada de saída linear. Os cálculos foram implementados no MATLAB, onde a rede foi treinada com um conjunto de 1130 padrões, permitindo que o modelo aprendesse a relação entre as variáveis de entrada e a porosidade.

Os resultados apresentados na Figura 23 do estudo representam a relação entre a porosidade do concreto e a relação água/cimento. Nota-se que, com o aumento da relação água/cimento, a porosidade do concreto também cresce, o que está em conformidade com o comportamento esperado do material. Além disso, observa-se uma boa correspondência entre os valores estimados pelo modelo e os obtidos experimentalmente, evidenciando a precisão da RNA na previsão da porosidade.

Esses resultados reforçam a eficácia do uso de redes neurais artificiais na previsão da porosidade do concreto, evidenciando o potencial dessa técnica como ferramenta eficiente para estimativas precisas a partir dos parâmetros dos materiais. Nesse contexto, o presente estudo adota redes neurais artificiais para estimar o índice de vazios do concreto e, com esse valor predito, realizar a simulação em mesoescala do material. Assim, a primeira fase da pesquisa consiste em empregar RNAs para mapear a porosidade do concreto, tendo como referência o proporcionamento da mistura.

Figura 23. Representação gráfica da porosidade calculada e estimada.



Fonte: Modificado de Nehme (2000).

2.5 REDES NEURAIS ARTIFICIAIS


Dentre as técnicas de Aprendizado de Máquina mencionadas anteriormente, Ludemir (2021) destaca as RNA como uma das técnicas que têm se mostrado eficazes na resolução de problemas associados ao mapeamento de propriedades do concreto. Sabendo disso, neste trabalho as RNAS são usadas para determinar o índice de vazios de concretos com e sem RCD conhecida a sua formulação, proporção dos materiais constituintes.

A inspiração biológica das RNAs vem da estrutura dos neurônios, que são as unidades fundamentais do sistema nervoso. Segundo Rauber, (2014), um neurônio biológico possui um núcleo e um corpo celular (soma), onde ocorrem reações químicas e elétricas responsáveis pelo processamento da informação (Figura 24). A saída dessa informação ocorre por meio de impulsos elétricos que percorrem o axônio, que se ramifica no final para distribuir sinais a outros neurônios vizinhos. A comunicação entre os neurônios ocorre por meio das sinapses, que conectam o axônio de um neurônio aos dendritos de outro. Quando um impulso elétrico atinge a sinapse, substâncias químicas são liberadas, transmitindo a informação e permitindo que o neurônio receptor processe o sinal e o retransmita.

De Cerqueira et al. (2001) descrevem que o comportamento dos neurônios biológicos é simulado por neurônios artificiais, que atuam como unidades básicas de processamento de informação. Assim como os neurônios biológicos, que possuem um corpo celular com dois conjuntos de ramificações, dendritos e axônio, os neurônios


artificiais apresentam um núcleo de processamento com múltiplos sinais de entrada (dendritos) e um único sinal de saída (axônio) (Figura 25). As informações recebidas pelos dendritos podem vir de sensores ou de outros neurônios artificiais na rede neural. Esses sinais são processados e transmitidos à saída, garantindo a continuidade do fluxo de informações. Para um processamento eficiente, todas as entradas devem alcançar o núcleo do neurônio simultaneamente, garantindo a sincronia necessária à transmissão correta dos dados.

Figura 24. Representação de neurônio biológico.



Fonte: Traduzido de Rauber (2014).

Figura 25. a) neurônio biológico e b) neurônio artificial.




Fonte: De Cerqueira et al. (2001).

Uma característica de grande importância do neurônio artificial é o peso sináptico, pois indica a influência de cada entrada na resposta de um neurônio, quando se avalia a primeira camada oculta (camada de processamento). Durante o processo de aprendizado, esses pesos são ajustados para permitir que a rede reconheça padrões e generalize a partir dos dados fornecido (ORLANDI, 1997).

De acordo com Martineli et al. (1999), cada conexão entre os neurônios de uma rede neural possui um peso associado, que pode ser representado pela variável w (peso). O peso sináptico define a importância de uma entrada no processamento de informação do neurônio e influencia diretamente a saída gerada pela rede.

Segundo Silva, Spatti e Flauzino (2010), os diversos sinais de entrada têm origem no meio externo e são representados pelo conjunto $\{x_1, x_2, \dots, x_n\}$, de maneira semelhante aos impulsos elétricos que atingem os neurônios biológicos. No modelo artificial, as junções sinápticas, responsáveis pela ponderação das informações no sistema biológico, são representadas pelo conjunto de pesos sinápticos $\{w_1, w_2, \dots, w_n\}$ como se apresenta na Figura 26 .

Figura 26. Esquema de processamento de informações do neurônio artificial.



Fonte: Modificado de RAUBER (2014).

Dessa forma, a importância de cada entrada (x_i) é determinada pela multiplicação por seu respectivo peso sináptico (w_i), permitindo a ponderação de todas as informações externas recebidas pelo neurônio. Assim, a saída do corpo celular artificial, denotada por (u), corresponde à soma ponderada das entradas, que podem ser determinadas por meio da Equação .

$$u = \sum_{i=1}^n w_i \cdot x_{i-\theta}$$

Equação 17

De acordo com Martineli et al. (1999) o valor de θ é denominado limiar de “threshold” do neurônio. Esse valor é então processado por uma função de ativação $g(\cdot)$.

2.5.1 Função de ativação


Segundo Silva, Spatti e Flauzino (2010), as funções de ativação podem ser classificadas em dois grupos principais, de acordo com a existência de suas derivadas ao longo do domínio: funções parcialmente diferenciáveis e funções totalmente diferenciáveis. As funções parcialmente diferenciáveis são aquelas que apresentam pontos em que a derivada de primeira ordem é inexistente. Entre as principais funções desse grupo, destacam-se a função degrau, a função degrau bipolar e a função rampa simétrica, amplamente utilizadas em redes neurais artificiais para representar comportamentos binários ou discretos.

Silva, Almeida e Yamakami (2012) descreve que a função limiar ou degrau normalmente restringe a saída do RNA a valores binários $[0,1]$ ou bipolares $[-1,1]$, sendo representada pela Equação 18. Na Figura 27, é representada a função de ativação em degrau.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases}$$

Equação 18

Figura 27. Função de ativação degrau.




Fonte: Modificado de ORLANDI, (1997).

Silva, Spatti e Flauzino (2010) especificam que a função degrau bipolar gera resultados unitários positivos quando o potencial de ativação do neurônio é maior que zero, valores nulos quando o potencial é zero e valores unitários negativos quando o potencial é menor que zero. Matematicamente, essa função pode ser expressa pela Equação 19. Na Figura 28, é representada a função de ativação degrau bipolar.

$$g(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad \text{Equação 19}$$

Figura 28. Função de ativação degrau bipolar.



Fonte: Modificado de Silva, Spatti e Flauzino, (2010).

Em alguns problemas envolvidos com classificação de padrões, a função degrau bipolar pode ser aproximada pela Equação 20.


$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ -1, & \text{se } u < 0 \end{cases} \quad \text{Equação 20}$$

No caso da função de ativação de rampa simétrica, Silva, Spatti e Flauzino (2010) descrevem que os valores de saída correspondem diretamente aos próprios valores dos potenciais de ativação quando estes pertencem ao intervalo $[-a, a]$. Caso contrário, a função é limitada aos valores extremos. Em notação matemática, tem-se a representação da função de ativação de rampa simétrica, conforme a Equação 21. Na Figura 29 é representada a função de ativação rampa simétrica

$$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases} \quad \text{Equação 21}$$

Conforme Silva, Spatti e Flauzino (2010), as funções de ativação diferenciáveis são aquelas cuja derivada é definida em todos os pontos de seu domínio. As principais funções desse grupo, amplamente empregadas em redes neurais artificiais, incluem a logística, a tangente hiperbólica, a gaussiana e a linear.

Figura 29. Função de ativação do tipo rampa simétrica.




Fonte: Modificado de Silva, Spatti e Flauzino (2010).

No caso da função logística, uma de suas principais características, segundo Amorim, (2015), consiste no fato de que suas saídas sempre assumem valores reais dentro do intervalo entre 0 e 1. Sua expressão matemática é dada pela Equação 22.

$$g(u) = \frac{1}{1 + e^{-\lambda \cdot u}} \quad \text{Equação 22}$$

sendo λ uma constante real associada ao nível de inclinação da função logística frente ao seu ponto de inflexão. Na Figura 30 é representada a função de ativação logística.

Figura 30. Função de ativação logística.




Fonte: Modificado de Silva (2018).

Segundo FLECK et al.,(2016), diferente da função logística, que possui valores de ativação apenas no intervalo (0,1), a função de ativação tangente hiperbólica mantém a forma sigmoidal da função logística, mas pode assumir valores tanto positivos quanto negativos (Figura 31). De acordo com Silva, Spatti e Flauzino (2010), o resultado de saída dessa função de ativação sempre assume valores reais entre -1 e 1, sendo definida pela Equação 23. Da mesma forma que na função logística, o valor λ está associado ao grau de inclinação da função tangente hiperbólica.

$$g(u) = \frac{1 - e^{-\lambda \cdot u}}{1 + e^{-\lambda \cdot u}} \quad \text{Equação 23}$$


Figura 31. Função de ativação tangente hiperbólica para diferentes valores de λ .



Fonte: Modificado de Silva, Spatti e Flauzino (2010).

Em relação à função de ativação gaussiana, Macedo (2012) descreve que seus resultados dependem da posição da saída do combinador linear em relação ao seu centro. Dessa forma, para valores equidistantes do centro, a saída do neurônio será a mesma, como se observa na Figura 32.

Figura 32. Função de ativação gaussiana.



Fonte: Modificado de Macedo (2012).

A função de ativação gaussiana pode ser descrita pela Equação 24, onde σ representa o desvio padrão e c corresponde o centro da função.


$$g(u) = e^{\frac{-(u-c)^2}{2\sigma^2}}$$
Equação 24

Por outro lado, Silva, Spatti e Flauzino (2010) especificam que as funções de ativação linear ou identidade, geram resultados de saída idênticos aos valores do potencial de ativação (u), sendo sua expressão matemática definida pela Equação 25.

$$g(u) = u$$
Equação 25

Uma das aplicações da função de ativação linear está no uso de RNAs como aproximadora universais de funções, com o objetivo de mapear o comportamento entre as variáveis de entrada e saída de processos. Na Figura 33 é representada a função de ativação linear.

Figura 33. Função de ativação Linear.



Fonte: Macedo (2012).

2.5.2 Arquitetura das RNAs


Uma rede possui uma arquitetura que determina a organização dos neurônios e suas conexões, sendo essa estrutura fundamental para orientar as conexões sinápticas. O treinamento dessa arquitetura envolve uma sequência estruturada de etapas, cujo objetivo é ajustar os pesos e os limiares dos neurônios. Esse processo

de ajuste, conhecido como algoritmo de aprendizagem (ou treinamento), busca calibrar a rede neural para que sua saída se aproxime dos valores reais (AMORIM, 2015).

A arquitetura é composta por diferentes camadas, conforme descrito por Martineli (1999). De forma geral, uma RNA possui uma camada de entrada, zero ou mais camadas intermediárias (ou ocultas) e uma camada de saída (Figura 34). A camada de entrada capta estímulos externos e os transmite à camada intermediária, enquanto a camada de saída representa a resposta da rede a uma determinada entrada. Entre essas duas camadas, as camadas intermediárias, quando presentes, desempenham um papel essencial no processamento de informações, e suas saídas são inacessíveis a procedimentos externos ao RNA.

Segundo Fleck et al. (2016), vale ressaltar que uma das maiores dificuldades no uso das RNAs é a definição da arquitetura mais adequada. Por ser um processo experimental, requer múltiplos testes e pode demandar um tempo significativo de execução.

Figura 34. Disposição de RNAs feedforward.




Fonte: Modificado de Rauber (2014).

De acordo com Amorim (2015), a arquitetura de uma rede neural pode ser classificada em quatro tipos: redes feedforward de camada simples, redes feedforward de camadas múltiplas, redes recorrentes (ou realimentadas) e redes com estrutura reticulada. Essa classificação considera a disposição dos neurônios, a forma como estão interligados e a organização das camadas que compõem a rede.

Segundo Silva, Spatti e Flauzino (2010), a arquitetura de redes neurais artificiais do tipo feedforward de camada simples é composta por uma camada de entrada e uma única camada de neurônios, que também funciona como camada de saída. A Figura 35 ilustra esse tipo de arquitetura, formada por n entradas e m saídas.


Figura 35. Exemplo de RNA com uma única camada de processamento (oculta).



Fonte: Silva, Spatti e Flauzino (2010).

Por outro lado, a arquitetura feedforward de múltiplas camadas pode ser utilizada para a previsão de séries temporais. Essa estrutura é composta por camadas de entrada e de saída, além de uma ou mais camadas ocultas. A complexidade do problema é o principal fator que determina tanto a quantidade de camadas ocultas quanto o número de neurônios na rede. (LOUBACK et al., 2020). A Figura 36 apresenta a estrutura de uma rede feedforward de múltiplas camadas.


Figura 36. Rede feedforward de camadas múltiplas.



Fonte: Barbosa, Freitas, Neves (2005).


Na arquitetura recorrente ou realimentada, os neurônios da camada de saída realimentam a rede com sinais de saída. Este tipo de característica torna a rede apta para ser utilizada em processamento dinâmico de informação, ou seja, em processos que variam com o tempo, como, por exemplo, a otimização e identificação de sistemas, controle de processos e previsão de séries temporais (SALVINO, 2018). A Figura 37 apresenta a estrutura de uma rede feedforward de múltiplas camadas.

Figura 37. Rede com arquitetura recorrente.



Fonte: Salvino (2018).

Figura 38. Rede com arquitetura reticulada.



Fonte: Salvino (2018).

Para Silva, Spatti e Flauzino (2010), uma das principais características das redes com estruturas reticuladas é a disposição espacial dos neurônios, que tem como objetivo a extração de características. Nesse tipo de rede, a localização dos neurônios está diretamente relacionada ao ajuste de seus pesos e limiares. Suas aplicações são diversas, abrangendo áreas como agrupamento (*clustering*), reconhecimento de

padrões, otimização de sistemas e análise de grafos. A Figura 38 apresenta uma rede com estrutura reticular.


2.5.3 Modelos de RNAs

De acordo com Haykin (2001), o Perceptron é a forma mais simples de uma rede neural artificial, sendo utilizado para a classificação de padrões linearmente separáveis. Esse modelo consiste em um único neurônio, equipado com pesos sinápticos ajustáveis e um bias, o que permite a adaptação dos parâmetros livres durante o treinamento.

O conceito de Perceptron foi introduzido por Rosenblatt (1958) como um modelo inspirado no funcionamento do cérebro. Nesse contexto, foi demonstrado que, quando os padrões utilizados no treinamento pertencem a duas classes linearmente separáveis, o algoritmo do Perceptron converge, ajustando os pesos de modo a posicionar a superfície de decisão como um hiperplano entre essas duas classes. A garantia matemática desse processo é estabelecida pelo teorema de convergência do Perceptron, que comprova a viabilidade do modelo para a classificação de padrões dessa natureza.

Segundo Silva, Spatti e Flauzino (2010), a simplicidade do Perceptron está relacionada à sua estrutura, composta por apenas uma camada neural contendo um único neurônio artificial (Figura 39). Como discutido anteriormente, com base na classificação das redes neurais de acordo com sua arquitetura, o Perceptron se enquadra no modelo feedforward de camada única. Nesse tipo de arquitetura, o fluxo de informações ocorre sempre no sentido da camada de entrada para a camada de saída, sem qualquer tipo de realimentação dos valores produzidos pelo neurônio. Essa característica reforça o fato de que o Perceptron é adequado para a classificação de padrões linearmente separáveis, como destacado no teorema de convergência do Perceptron.

Figura 39. Rede Perceptron.



Fonte: Silva, Spatti e Flauzino (2010).

Matematicamente, o processamento interno do Perceptron pode ser descrito pelas Equações 21 e 26.

$$y = g(u)$$


Equação 26

Os dados de entrada, representados na Equação 21 por (x_i) , contêm informações sobre o comportamento do processo a ser mapeado. Esses dados são ponderados pelos pesos sinápticos (w_i) , o que permite quantificar a relevância de cada entrada em relação aos objetivos funcionais atribuídos ao neurônio. O objetivo desse mapeamento é estabelecer a relação entre a entrada e a saída do processo analisado.

Após essa etapa, o valor resultante da composição das entradas ponderadas, somado ao limiar de ativação (θ) , é utilizado como argumento da função de ativação. O resultado dessa função determina a saída (y) gerada pelo Perceptron.

Segundo Widrow, Hoff e (1960), as RNAs podem ser classificadas como Adaline (Adaptive Linear Neuron), que é um modelo de neurônio artificial voltado para aprendizado adaptativo, com aplicações em reconhecimento de padrões e processamento de sinais. Sua principal característica é a atualização dos pesos por meio do algoritmo LMS (Least Mean Squares), também conhecido como Regra Delta, que reduz progressivamente a diferença entre a saída prevista e o valor desejado, ajustando os pesos de forma incremental. Os autores descrevem a estrutura da Adaline como um neurônio linear único, no qual a saída é obtida pela combinação ponderada das entradas e de seus respectivos pesos sinápticos, conforme ilustrado na Figura 40.

Figura 40. Rede Adaline.



Fonte: Modificado de Widdrow e Hoff (1960).

Silva, Spatti e Flauzino (2010). descrevem que, assim como na Rede Perceptron, a Adaline computa a potência de ativação (u) por meio da soma das contribuições resultantes da multiplicação de todos os sinais de entrada (x_i) pelos respectivos pesos sinápticos (w_i), incluindo o valor do limiar (θ). A saída (y) da Adaline é então obtida pela aplicação da função de ativação $g(u)$, que é geralmente representada pela função degrau ou função degrau bipolar. O processo de cálculo da saída segue a mesma lógica empregada na Rede Perceptron, podendo ser descrito pela Equação e Equação .

No caso da rede Adaline é possível evidenciar na Figura 40 a presença de um bloco associador, assim como um sinal de erro que pode ser obtido por meio da Equação 27.

$$erro = d - u$$

Equação 27

Para cada amostra de treinamento, a atualização dos pesos da rede ($w_0, w_1, w_2, \dots, w_n$) é realizada com base no erro, definido como a diferença entre o potencial de ativação (u) gerado pela rede e o valor desejado (d). Esse erro é essencial para o ajuste dos pesos, permitindo a melhoria contínua do modelo.

Assim, com o objetivo de minimizar esse erro e aprimorar o desempenho da rede, Widrow e Hoff (1960) propuseram o método de ajuste de pesos baseado na regra de aprendizado por correção do erro (Regra Delta). Esse processo de atualização é determinado pela seguinte equação:


$$w_i(t + 1) = w_i(t) + \eta \cdot (d - y) \cdot x_i$$

Equação 28

Onde $w_i(t)$ representa o peso no instante de tempo (t), enquanto $w_i(t + 1)$ corresponde ao peso atualizado no instante ($t + 1$). O parâmetro (η) é a taxa de aprendizado, que de acordo com Orlandi, (1997), influencia diretamente a performance do aprendizado por correção do erro. Quando (η) assume um valor pequeno, o processo de aprendizado ocorre de forma gradual, mas a convergência para uma solução estável pode ser lenta. Por outro lado, se (η) for muito alto, o aprendizado se torna mais rápido, porém há o risco de instabilidade e divergência do sistema.

Segundo Haykin (2001), as redes Perceptron de Múltiplas Camadas (Figura 41), também conhecidas como MLP (Multi-Layer Perceptron), são uma generalização do Perceptron de camada única. Essas redes são compostas por um conjunto de unidades sensoriais, ou nós de fonte, que formam a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída. O sinal de entrada percorre a rede diretamente, propagando-se de camada em camada até atingir a saída.

Figura 41. Perceptron de múltiplas camadas com duas camadas ocultas.




Fonte: Modificado de Haykin (2001).

Para treinar essas redes MLP, utiliza-se o algoritmo de retropropagação do erro (backpropagation), o mesmo princípio empregado no Perceptron. Esse algoritmo foi desenvolvido com base na aprendizagem por correção de erro, permitindo o ajuste iterativo dos pesos da rede de forma eficiente. A Figura 42 apresenta uma representação simplificada do processo de cálculo do backpropagation, conforme descrito por Felix, Possan e Carrazedo (2021).

O processo de treinamento de uma rede neural MLP com o algoritmo de retropropagação pode ser descrito como uma sequência iterativa de etapas bem definidas. Inicialmente, os pesos de todos os neurônios da rede são definidos aleatoriamente, garantindo que o treinamento comece de forma não enviesada. Essa etapa é crucial para permitir que os neurônios desenvolvam comportamentos distintos ao longo do processo de aprendizagem.

Com os pesos inicializados, o treinamento segue com a apresentação de um padrão de entrada à rede, que é processado na direção da saída (*feedforward*). Nesse momento, cada neurônio calcula sua ativação com base na soma ponderada das entradas recebidas e em uma função de ativação não linear. O sinal avança pelas camadas até atingir a camada de saída, onde os valores produzidos pela rede são comparados aos valores esperados.

Figura 42. Fluxograma do algoritmo de backpropagation.



Fonte: Própria autoria.

A diferença entre a saída produzida e a desejada é utilizada para calcular o erro da rede. Esse erro é então propagado de volta pelas camadas (*backpropagation*), permitindo o cálculo dos gradientes necessários para ajustar os pesos sinápticos. Inicialmente, ajustam-se os pesos da camada de saída, e em seguida, se houver camadas ocultas, ajustam-se seus respectivos pesos utilizando a mesma lógica, com base na contribuição de cada neurônio para o erro final.

Após a retropropagação do erro, verifica-se se o erro total está dentro de um

limite aceitável. Se o erro for considerado satisfatório (por exemplo, igual a zero ou inferior a um valor de tolerância), o treinamento pode ser encerrado. Caso contrário, o algoritmo verifica se há mais padrões de entrada a serem apresentados e repete o processo com o próximo padrão. O ciclo se repete até que todos os padrões tenham sido apresentados e os pesos ajustados adequadamente, ou até que se atinja um critério de parada, como o número máximo de épocas ou o erro mínimo.

Esse processo iterativo de ajuste contínuo dos pesos permite que a MLP aprenda a modelar relações complexas entre os dados de entrada e de saída, sendo amplamente utilizado em aplicações como o reconhecimento de padrões, a previsão de séries temporais e a classificação de dados.

3 MATERIAIS E MÉTODOS: FORMATO ARTIGOS

Os materiais utilizados no projeto, o método adotado, os resultados obtidos e suas respectivas discussões estão apresentados em forma de artigos que seguem. O primeiro artigo está relacionado à determinação de um modelo preditivo do índice de vazios em concretos, e o segundo, à modelagem numérica do concreto em mesoescala.

APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA A PREDIÇÃO DO ÍNDICE DE VAZIOS DE CONCRETOS COM AGREGADOS DE DIFERENTES ORIGENS

Jairo O. F. Barreto^{a*} e Emerson F. Felix^b

^a Pós-Graduação em Engenharia Civil, Universidade Federal de Integração Latino-Americana, Foz do Iguaçu, Brasil e-mail: jairobarretof@gmail.com

^b Departamento de Engenharia Civil, Faculdade de Engenharia e Ciências, Universidade Estadual Paulista, Guaratinguetá 12516-410, Brasil e-mail: emerson.felix@unesp.br

Resumo

O presente estudo avalia a aplicação de redes neurais artificiais do tipo Multilayer Perceptron para a definição de um modelo preditivo do índice de vazios em concretos produzidos com agregados de diferentes origens, incluindo materiais naturais e resíduos de construção e demolição. A modelagem foi desenvolvida com base em um conjunto de dados compilado a partir de diferentes estudos experimentais, incorporando a variabilidade inerente aos materiais e aos processos produtivos. O estudo foi conduzido em três etapas: (i) construção e análise estatística de um banco de dados, definindo o domínio de validade; (ii) treinamento e validação de 120 arquiteturas de RNAs, com uma e duas camadas ocultas e diferentes números de neurônios, utilizando validação cruzada; e (iii) avaliação do desempenho dos modelos com base em R^2 e RMSE, selecionando a configuração com maior capacidade de generalização. Os resultados obtidos indicam o desempenho preditivo dos modelos desenvolvidos. A rede com uma única camada oculta apresentou coeficiente de determinação ponderado (R^2) de 0,81, enquanto a configuração com duas camadas ocultas alcançou R^2 de 0,87, o que demonstra que o aumento da profundidade da rede contribuiu para o aprimoramento das previsões. Em particular, a topologia [6-7-5-1] apresentou desempenho superior, com coeficiente de determinação de 0,89 e erro percentual médio absoluto de 6,4%. Os resultados do estudo apontam a viabilidade e a eficácia da aplicação de redes neurais artificiais na predição do índice de vazios em concretos com agregados de diferentes origens, o que propicia uma ferramenta com parâmetros de fácil manipulação e baixo erro nas previsões.

Palavras-chave: *Concreto; Agregados Naturais; Agregados de RCD; Índice de Vazios, Redes Neurais Artificiais.*

1. Introdução

A estimativa das propriedades mecânicas do concreto, como o módulo de elasticidade, é essencial para a concepção e a avaliação do desempenho das estruturas. A maioria das formulações analíticas, depende do conhecimento prévio dos módulos de elasticidade das fases constituintes do concreto (a matriz cimentícia e o agregado graúdo), bem como de suas proporções volumétricas. Tais informações, embora muitas vezes disponíveis nas fases de concepção e dosagem, podem se tornar imprecisas ou indisponíveis nas fases de projeto estrutural ou na avaliação do comportamento de estruturas existentes. Nesse contexto, a necessidade de estimativas adicionais introduz incertezas e potenciais erros nas análises estruturais.

Com o avanço da capacidade computacional e o crescente interesse por abordagens numéricas, técnicas como o Método dos Elementos Finitos (MEF) vêm sendo cada vez mais aplicadas à modelagem do concreto em macro e mesoescala. A modelagem em mesoescala permite representar o concreto como um material heterogêneo, considerando a distribuição espacial das fases (matriz, agregado e interface), o que viabiliza simulações mais realistas do comportamento mecânico do material. Estudos recentes demonstram o potencial do MEF na reprodução de fenômenos estruturais complexos e na análise de propriedades físico-mecânicas, como a rigidez efetiva ou a concentração de tensões e progressão de fissuras, a partir de representações detalhadas do compósito (LEE et al., 2009, ZHU; CHEN, 2012, ZHOU; LI; MA, 2014).

Apesar dos avanços significativos no uso de técnicas numéricas para modelar o comportamento do concreto em mesoescala, grande parte dos modelos desenvolvidos ainda carece de aplicabilidade prática, especialmente quanto à calibração dos parâmetros físico-mecânicos. Isso ocorre principalmente devido à exigência de parâmetros difíceis de definir, associados a cada uma das fases que compõem o compósito, especialmente quando se considera a porosidade como um meio a ser simulado. A representação dos vazios ainda constitui um desafio relevante, uma vez que sua presença afeta diretamente a rigidez e a resistência do concreto, mas sua quantificação e distribuição são difíceis de determinar experimentalmente (WANG et al., 2015).

A dificuldade em obter o índice de vazios de forma analítica, sobretudo em concretos com agregados não naturais, cuja variabilidade é elevada, torna os métodos experimentais tradicionais (como os ensaios de absorção de água, massa específica e permeabilidade,

conforme NBR 9778 (ABNT, 2018) e ASTM C642 (ASTM, 2009) muitas vezes inviáveis em estudos numéricos mais amplos, devido à demanda de tempo, de estrutura laboratorial e de materiais.

Diante dessas limitações, o uso de técnicas baseadas em Aprendizado de Máquina tem se mostrado promissor, possibilitando a predição de propriedades do concreto sem a necessidade de ensaios destrutivos (GAMIL, 2023). O Aprendizado de Máquina, ramo da inteligência artificial, utiliza algoritmos capazes de identificar padrões em bases de dados e realizar previsões com alta precisão (MITCHELL, 1997).

Redes neurais artificiais (RNAs), em especial do tipo Multi-Layer Perceptron, vêm sendo aplicadas à predição de propriedades como resistência à compressão (MORAES; SANTOS, 2022), módulo de elasticidade (MORETTI, 2010) e índice de vazios (SANTOS et al., 2024), demonstrando bom desempenho, inclusive em concretos com agregados oriundos de resíduos de construção e demolição (RCD), que apresentam elevada variabilidade nas propriedades físico-mecânicas (FROTTE et al., 2017; OLIVEIRA et al., 2023).


As redes neurais artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por unidades chamadas neurônios artificiais, organizadas em camadas interconectadas por pesos ajustáveis. Essas camadas incluem uma de entrada, uma ou mais camadas ocultas e uma de saída, responsáveis por processar e transformar os dados de entrada em respostas computacionais (HAYKIN, 2001). A principal vantagem das RNAs está em sua capacidade de aprender padrões a partir de dados, mesmo em problemas altamente complexos e com relações não lineares entre variáveis (PAIXÃO, 2025).

O desenvolvimento das RNAs teve início com os primeiros modelos de neurônios na década de 1940, mas foi com a criação do Perceptron (Figura 1a) por Rosenblatt (1958) que se estabeleceu uma base significativa para a área. Contudo, as limitações das redes de camada única levaram a uma desaceleração nas pesquisas, que só foi revertida a partir da década de 1980, com a introdução do algoritmo de retropropagação do erro por Rumelhart et al. (1986), que possibilitou o treinamento de redes com múltiplas camadas ocultas, ampliando significativamente sua capacidade de representação.

Redes do tipo Multilayer Perceptron (MLP), compostas por uma ou mais camadas ocultas (com mais de um neurônio) (Figura 1b), são amplamente empregadas na resolução de problemas de regressão e classificação. Segundo o Teorema da Aproximação Universal (CYBENKO, 1989), mesmo uma MLP com apenas uma camada oculta é capaz de aproximar qualquer função

contínua, desde que a função de ativação utilizada seja não linear. Esse resultado foi reforçado por Hornik (1991), que demonstrou que o número de camadas e neurônios pode ser ajustado conforme a complexidade do problema, garantindo flexibilidade e robustez nos modelos.

Figura 1. Arquitetura de RNAs com a) uma camada oculta e b) duas camadas ocultas



Fonte: (a) Silva, Spatti e Flauzino (2010); (b) Editado de Barbosa, Freitas e Neves (2005).

Para problemas de maior complexidade, redes com duas ou mais camadas ocultas têm-se mostrado mais eficazes, oferecendo maior capacidade de generalização (LECUN et al., 2015). Essas redes são particularmente úteis quando se deseja prever propriedades de compósitos heterogêneos, como o concreto, em que os dados apresentam elevada variabilidade e relações não lineares entre os parâmetros envolvidos. A literatura apresenta diversos exemplos de aplicação das RNAs no mapeamento de propriedades do concreto (NEHME, 2000; LEE et al., 2022; FELIX et al., 2021; ALMEIDA et al., 2024; SANTOS et al., 2024; LUNARDI et al., 2025). Nehme (2000), por exemplo, utilizou uma rede simples com 10 neurônios na camada oculta para prever a porosidade do concreto. Le et al. (2022) adotaram uma abordagem mais robusta com 512 neurônios em uma única camada, enquanto Santos et al. (2024) optaram por uma rede com duas camadas ocultas de seis neurônios cada, visando lidar com a complexidade das variáveis envolvidas.

O sucesso das RNAs em tarefas de predição pode ser atribuído à sua estrutura funcional. De acordo com Haykin (2001), uma RNA é composta por cinco elementos principais: um conjunto de entradas ponderadas pelos pesos sinápticos, um somador que agrega essas entradas, uma função de ativação que limita a saída, um bias que ajusta a entrada líquida da função e, por fim, a saída da rede. Essa estrutura, que simula, de forma simplificada, o comportamento das redes neurais biológicas, permite que as RNAs aprendam e generalizem a partir de exemplos práticos, sem a necessidade de formulações matemáticas explícitas.

Na área de materiais, redes neurais artificiais (RNAs) têm sido amplamente utilizadas para estimar propriedades mecânicas do concreto, como a resistência à compressão (NI; WANG, 2000; KIM, 2005; OZTAS et al., 2006; ALSHIHRI et al., 2009; DIAB et al., 2014) e o módulo de elasticidade (TOPÇU; SARIDEMIR, 2007; DUAN et al., 2017; GHOLAMPOUR et al., 2017). Além disso, as RNAs também foram aplicadas para avaliar a trabalhabilidade do concreto (JAIN, 2008; DEEPAK et al., 2019), a consistência da mistura no estado fresco (POON et al., 2007) e até mesmo para prever os componentes e proporções ideais da dosagem do concreto (JI et al., 2006).

Estudos que relacionam de forma multidisciplinar as áreas de materiais e estruturas, como aqueles voltados à análise da durabilidade, também vêm sendo desenvolvidos ao longo dos últimos anos (SMETS et al., 1992; TRASATTI; MAZZA, 1996; CAI et al., 1999; TOPÇU et al., 2009; KARAKOÇ et al., 2011; FELIX et al., 2019; ALMEIDA et al., 2024, SANTOS et al., 2024; LUNARDI et al., 2025). Parthiban et al. (2005) demonstraram a eficácia do uso de RNAs na construção de modelos preditivos do potencial de corrosão das armaduras em estruturas de concreto armado, alcançando estimativas com erro inferior a 5%. Já Ukrainczyk e Ukrainczyk (2008) evidenciaram o potencial das RNAs na análise da sensibilidade e da influência de diversos parâmetros relacionados à corrosão, como condições ambientais, geometria estrutural, condições de contorno e propriedades dos materiais, para a avaliação de danos em pontes de concreto.


Deste modo, o presente estudo aplica RNAs do tipo MLP para mapear o índice de vazios (IV) em concretos com agregados de diferentes origens, naturais ou provenientes de resíduos de construção e demolição (RCD). Na modelagem são empregados dados provenientes de diferentes grupos de trabalho, considerando a heterogeneidade associada aos materiais e ao processo de produção. Como principal contribuição, a modelagem considera apenas dados de fácil obtenção, como a proporção dos materiais da mistura, o tipo de cimento e a origem do agregado, o que facilita o uso da ferramenta numérica por outros pesquisadores e profissionais da área.

2. Modelagem do IV com RNAs

Considerando o objetivo de aplicar RNAs para desenvolver um modelo de estimativa do índice de vazios dos concretos com diferentes agregados, utilizou-se, no trabalho, o fluxo de processos e as metodologias indicados na Figura 2. A Etapa 1, refere-se à definição de um banco de dados

e seu processamento e análise estatística. Os dados foram tratados para identificar possíveis inconsistências e o domínio de validade do modelo gerado. Na Etapa 2, com os dados já coletados e devidamente tratados, foram realizados os treinamentos das RNAs, nos quais foram avaliadas 120 configurações diferentes (arquiteturas), variando o número de camadas ocultas (uma ou duas) e o de neurônios (1-20). O treinamento foi conduzido considerando a divisão do banco de dados em conjuntos de treino e de teste. Foram conduzidas validações cruzadas para reduzir a tendência de supertreinamento (overfitting) que pode ocorrer no treinamento de modelos de aprendizado de máquina. Por fim, na Etapa 3, os resultados foram avaliados com base no desempenho das RNAs nos conjuntos de treino e de teste, utilizando como métricas o coeficiente de determinação (R^2) e o erro quadrático médio (RMSE), o que permitiu inferir o modelo com maior capacidade de generalização. Esses principais processos são detalhados na sequência, indicando todos os materiais (dados) e métodos.

Figura 2. Principais processos e métodos empregados no trabalho.



Fonte: Própria autoria.

2.1 Definição do banco de dados

A Tabela 1 apresenta as variáveis de entrada (*inputs*) e de saída (*outputs*) utilizadas no modelo de redes neurais artificiais desenvolvido neste estudo. A base de dados foi construída a partir da seleção de informações extraídas da literatura técnica e científica, incluindo dissertações, artigos, periódicos especializados e outras fontes relevantes. Ao final do processo de coleta, foram identificadas 199 amostras de traços de concreto, com e sem substituição por resíduos de construção e demolição (RCD), todas com a respectiva medição do índice de vazios como variável de saída.

Na Tabela 2, apresenta-se a distribuição desses dados conforme os autores e os estudos de origem, evidenciando a diversidade das fontes utilizadas para compor a base da modelagem.

Tabela 1. Dados de entrada e saída no modelo.

Dado	Nomenclatura	Tipo de variável
Tipo de cimento	CTYPE	Entrada
Quantidade de Cimento (kg/m ³)	CC	Entrada
Tipo de agregado	ATYPE	Entrada
Quantidade de agregado (kg/m ³)	AC	Entrada
Taxa de substituição de agregado natural por RCD (%)	TS	Entrada
Relação água-cimento	W/C	Entrada
Índice de vazios	IV	Saída

Fonte: Própria autoria.

Tabela 2. Quantidade de dados coletados da literatura.

Referência dos dados	No. de Dados
Ahmad et al. (2013)	18
Tedesco (2016)	18
Frotte et al. (2017)	18
Tenório et al. (2007)	15
Nunes (2017)	15
Meireles (2005)	15
Younsi et al. (2010)	10
Pedrosa (2012)	9
Ugioni; Santos (2017)	8
Vieira et al. (2016)	7
Silva (2017)	6
Athayde (2020)	6
Pedro et al. (2014)	6
Costa (2018)	5
Franchini (2021)	5
Maia et al. (2022)	5
Filho (2021)	5
Estolano et al. (2018)	5
Gerin (2020)	4
Cartuxo et al. (2010)	4
Silva, Capuzzo (2020)	4
Piovesan (2016)	3
Nogueira (2020)	2
Junior (2021)	2
Gomes et al. (2021)	2
Pimentel e Bittencourt (2018)	1
Souza et al. (2023)	1

Fonte: Própria autoria.

As referências bibliográficas utilizadas neste estudo abordam, em sua maioria, investigações experimentais de propriedades físico-mecânicas de concretos com agregados naturais e RCD ou concretos exclusivamente produzidos com RCD. Em geral, os trabalhos da literatura disponibilizados

forneceram todas as propriedades dos materiais utilizados. No entanto, em alguns casos, as quantidades dos componentes da mistura não foram explicitamente informadas.

Diante disso, foi necessário calcular essas quantidades com base nas informações disponíveis. Utilizando-se dos traços nominais, das massas específicas dos materiais e da formulação proposta por Marmitti et al. (2016) (Equação 1), foi possível estimar a quantidade de cimento (c), bem como as proporções dos agregados miúdos e graúdos presentes nas misturas analisadas.

$$c = \frac{1000}{\frac{1}{\gamma_c} + \frac{a}{\gamma_a} + \frac{b}{\gamma_b} + \frac{w}{c}} \quad \text{Equação 1}$$

em que “ a ”, “ b ” e “ $\frac{w}{c}$ ” a massa de areia, massa de brita e massa de água em relação a massa de cimento, e $\gamma_c, \gamma_a, \gamma_b$ a massa específicas do cimento, areia e brita respectivamente.

2.2 Processamento e análise dos dados

Com o objetivo de aprimorar o desempenho das técnicas de aprendizado de máquina no treinamento do índice de vazios, aplicou-se ao conjunto base dos dados o método de detecção de outliers baseado no método intervalo interquartil (IQR), conforme proposto por Moura Santos, (2006). IQR é calculado pela diferença entre o terceiro quartil (Q_3) e o primeiro quartil (Q_1), conforme a Equação 2. Este método vem sendo amplamente empregado para identificar dados que se desviam do comportamento geral do banco de dados.

$$IQR = Q_3 - Q_1 \quad \text{Equação 2}$$

Com base nesse valor, definem-se os limites inferior (LI) e superior (LS), pelas Equações 3 e 4, respectivamente.

$$LI = Q_1 - 1.5 * IQR \quad \text{Equação 3}$$


$$LS = Q_3 + 1.5 * IQR \quad \text{Equação 4}$$

Os dados que se encontravam fora do intervalo definido pelos limites inferior e superior foram considerados valores discrepantes (outliers) e, conseqüentemente, removidos da base de dados. A identificação desses pontos foi realizada por meio de uma análise visual, com gráficos

combinados de boxplot e stripplot (Figura 3), que permitiram observar a dispersão dos valores e evidenciar os casos atípicos do índice de vazios.

O valor do intervalo interquartil (IQR) obtido foi de 0,065, resultando em um limite inferior (LI) de 0,0136 e um limite superior (LS) de 0,2736. A remoção dos dados fora desse intervalo teve como objetivo evitar distorções nos resultados da modelagem, garantindo maior consistência e representatividade à base de dados utilizada no treinamento da rede neural. Na Tabela 3 são apresentados os parâmetros estatísticos dos dados após a remoção dos outliers detectados pelo método IQR.

Figura 3. Distribuição do IV, boxplot, stripplot e outliers.



Fonte: Própria autoria.

Tabela 3. Parâmetros estatísticos do banco de dados das variáveis contínuas.


Unidade	CC (kg/m ³)	AC (kg/m ³)	TS (-)	W/C (-)	IV (-)
Média	339,48	1602,06	0,45	0,57	0,14
Desvio	84,32	362,86	0,38	0,12	0,04
Min	126,05	759,90	0,00	0,27	0,05
25%	300,00	1304,81	0,00	0,50	0,11
50%	341,67	1689,41	0,40	0,56	0,14
75%	383,70	1841,93	1,00	0,64	0,16
Max	550,00	2474,50	1,00	1,02	0,27

Fonte: Própria autoria.

De acordo com Lopez (2010), a distribuição de frequência é uma ferramenta fundamental para sintetizar e organizar dados coletados, permitindo sua apresentação de forma clara e significativa. Essa abordagem facilita a interpretação dos resultados e a identificação de padrões

relevantes no conjunto de dados. Neste estudo, foram elaborados gráficos de distribuição de frequência tanto para as variáveis de entrada quanto para a variável de saída. Para as variáveis contínuas, optou-se por utilizar histogramas combinados com curvas de densidade (KDE), enquanto, para as variáveis discretas, foram empregados gráficos de barras. Todos os gráficos foram desenvolvidos com o auxílio da biblioteca Seaborn, em ambiente Python, o que possibilitou uma visualização clara e eficiente das distribuições e variações dos dados analisados (Figura 4).

Figura 4. Distribuição e frequências dos dados.



Fonte: Própria autoria.

A análise dos gráficos da Figura 4 revela a presença de variáveis discretas no conjunto de dados, como o tipo de cimento e o tipo de agregado. O tipo de cimento foi categorizado com base na equivalência aos cimentos Portland produzidos no Brasil, definindo-se os seguintes rótulos: 1 para CP-V, 2 para CP-II e 4 para CP-IV, sendo o CP-V o mais frequente entre os registros analisados (concretos do tipo CP-III foram eliminados do banco de dados por apresentarem menos de 10 amostras, o que não lhes confere representatividade no domínio da variável). De maneira semelhante, o tipo de agregado foi classificado como 0 para agregado natural, 1 para agregado de RCD contendo apenas materiais cimentícios e 2 para agregado de RCD misto, sendo este último o mais representativo na base de dados (Tabela 4).

Tabela 4. Distribuição das variáveis discretas do banco de dados.

Variável	Categoria	Descrição	Frequência
CTYPE	1	CP-V	111
CTYPE	2	CP-II	62
CTYPE	4	CP-IV	20
ATYPE	0	Agregado Natural	52
ATYPE	1	Agregado cimentício	44
ATYPE	2	Agregado misto	97


Fonte: Própria autoria.

A análise dos histogramas das variáveis contínuas permitiu identificar tendências relevantes. O consumo de cimento, por exemplo, apresenta maior frequência no intervalo de 300 a 400 kg/m³, com distribuição aproximadamente normal quando considerado o intervalo de 200 a 400 kg/m³. Para o consumo total de agregados, observou-se um pico de ocorrência entre 1750 e 2000 kg/m³, seguido de uma queda acentuada fora desse intervalo. A relação água/cimento apresentou valores mais concentrados entre 0,5 e 0,7, enquanto o índice de vazios apresentou sua maior incidência no intervalo de 0,10 a 0,17.

Com o objetivo de avaliar a relação entre as variáveis, aplicou-se a correlação de Pearson, que, segundo Hernández e Peñaloza (2018), permite mensurar o grau de correspondência linear entre duas variáveis contínuas. A Figura 5 apresenta os coeficientes de correlação obtidos, destacando o maior valor, uma correlação fraca de 0,37 (correlação fraca ocorre para valores entre 0,20 e 0,49), entre o índice de vazios e o tipo de agregado utilizado. As demais variáveis analisadas

apresentaram correlações muito fracas ou inexistentes com o índice de vazios, indicando baixa dependência linear em relação aos parâmetros.

Figura 5. Matriz de correlação linear de Pearson.




Considerando que as correlações lineares são fracas ou inexistentes, avaliou-se a presença de correlação não linear por meio da análise de importância, utilizando o método de regressão baseado em florestas aleatórias (FAs). De acordo com Cutler, Cutler e Stevens (2012), esse método permite identificar o grau de influência de cada variável na previsão do parâmetro de interesse e é amplamente utilizado em problemas de aprendizado supervisionado.

Para a análise, o algoritmo foi configurado com uma floresta contendo 100 árvores, utilizando o erro médio quadrático (RMSE) como critério para avaliar a qualidade das divisões em cada árvore. Como resultado, o modelo gerou uma lista com a importância relativa de cada variável preditora para o desempenho da rede (Figura 6).

Os resultados da análise de importância das variáveis indicaram que o tipo de cimento foi o parâmetro de maior influência na previsão do índice de vazios, com importância relativa superior a 30%. Esse comportamento pode estar relacionado às diferenças na composição química, na finura e na presença de adições minerais entre os diferentes tipos de cimento, fatores que influenciam diretamente o processo de hidratação, a formação dos produtos hidratados e a microestrutura da pasta cimentícia. Consequentemente, essas características

afetam a porosidade da matriz e a interface entre a pasta e o agregado, o que se reflete no índice de vazios do concreto (Bentz et al., 2008; Lee & Lee, 2019; MEHTA & MONTEIRO, 2006).

Figura 6 . Análise de correlação não-linear por nível de importância, com modelo gerado por FAs.



Fonte: Própria autoria.

Por outro lado, a quantidade de cimento apresentou a menor contribuição relativa, com peso aproximado de 7,5% na capacidade preditiva do modelo. Esse resultado sugere que, na faixa de dados analisada, o consumo de cimento, isoladamente, não exerce influência tão significativa sobre o índice de vazios quanto os parâmetros relacionados à composição do material e às características dos agregados. Além disso, o efeito do consumo de cimento pode estar parcialmente captado por outras variáveis do modelo, como a relação água/cimento e o tipo de cimento utilizado.

2.3 Modelagem com Redes Neurais Artificiais

De acordo com Silva, Spatti e Flauzino (2010), uma rede neural artificial é composta por três partes principais: a camada de entrada, as camadas ocultas (também chamadas de escondidas ou internas) e a camada de saída. Cada uma dessas partes desempenha uma função específica e complementar no processamento de informações.


Segundo Belotti (2019), a camada de entrada é responsável por receber os dados iniciais da rede, representados por $X = \{x_1, x_2, x_3, \dots, x_n\}$. Esses valores, em geral, passam por um processo de normalização para adequá-los à escala de atuação das funções de ativação dos neurônios, além de assegurar que todos os parâmetros estejam na mesma escala e não interfiram no mapeamento. As camadas ocultas, por sua vez, são formadas por neurônios responsáveis pelo

processamento interno das informações, extraindo os padrões e as características mais relevantes do problema analisado. A camada de saída é responsável por gerar o resultado final da rede, encerrar o processamento e fornecer a resposta prevista pelo modelo.

Com base nesses fundamentos, o presente estudo investigou duas configurações-base de redes neurais artificiais, ambas utilizando as mesmas seis variáveis de entrada (o tipo de cimento “CTYPE”; o consumo de cimento, em kg/m^3 “CC”; o tipo de agregado graúdo “ATYPE”; o consumo total de agregados, em kg/m^3 “AC”; a taxa de substituição de agregado natural por RCD, em %, “TS”; a relação água-cimento “W/C”). A principal diferença entre as configurações-base reside na quantidade de camadas ocultas. As RNAs geradas pela primeira arquitetura são compostas por uma única camada oculta, com 1 a 20 neurônios. Já as criadas com a segunda camada possuem duas camadas ocultas, cada uma com o número de neurônios variando de 1 a 10. Em ambas as configurações, há uma camada de saída responsável pela predição do índice de vazios.

As representações dessas duas arquiteturas são apresentadas na Figura 7, permitindo a visualização da estrutura e da organização das camadas e dos neurônios em cada modelo analisado.

Figura 7. Configurações-base usadas em RNAs com: a) uma camada oculta; e b) duas camadas ocultas.



Fonte: Própria autoria.

Deste modo, foram gerados, treinados e testados 120 RNAs: 20 com uma camada oculta e 100 com duas camadas ocultas. Para identificar a configuração com melhor desempenho preditivo, foram testadas diferentes estruturas, variando-se o número de neurônios nessa camada entre 1 e 20. Todas as RNAs foram treinadas com função de ativação logística, considerando um número máximo de iterações de 100.000, com uma verificação de melhora do erro médio quadrático em um intervalo de 10.000 iterações, e considerando 80% dos dados para treinar o

modelo e 20% para testar/validar. Para a modelagem, utilizou-se a validação cruzada e empregaram-se as bibliotecas do scikit-learn, no ambiente de modelagem do Jupyter, em Python.

Esses ajustes tiveram como objetivo explorar combinações que maximizassem o desempenho da rede neural, favorecendo uma boa capacidade de generalização e maior precisão nas previsões. Cada configuração foi treinada com um limite máximo de 1 milhão de iterações, garantindo tempo suficiente para a convergência dos modelos, sem interrupções prematuras. O algoritmo de treinamento usado foi o ADAM (Adaptive Moment Estimation), que é um otimizador estocástico disponível no Scikit-Learn usado para treinar redes neurais (como o MLPClassifier e o MLPRegressor). Adam é um algoritmo de otimização alternativo ao gradiente descendente estocástico para treinamento de modelos de aprendizado profundo.

3 Resultados e discussões

3.1 Análise de performance das RNAs treinadas

A avaliação do desempenho das redes neurais artificiais, tanto com uma quanto com duas camadas ocultas, foi realizada com base em duas métricas estatísticas: o coeficiente de determinação (R^2) (Equação 5) e a raiz do erro quadrático médio (RMSE) (Equação 6). Segundo Bermond et al. (2021), essas métricas indicam, respectivamente, a qualidade do ajuste do modelo, ou seja, sua capacidade de explicar os dados observados, e a magnitude média dos erros de predição.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{Y})^2} \quad \text{Equação 5}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad \text{Equação 6}$$

em que (y_i) é o valor observado, ($\tilde{y}_i$) valor predito pelo modelo, ($\bar{Y}$) média dos valores observados, e (n) o número total de observações.

No algoritmo criado para a modelagem com as RNA, foram conduzidas análises distintas nos conjuntos de treinamento e de teste, com o cálculo individual de R^2 e RMSE em cada etapa.


Para permitir uma avaliação conjunta e mais equilibrada do desempenho do modelo, adotou-se uma métrica adicional: o coeficiente de determinação ponderado ($R^2_{\text{Ponderado}}$). Esse indicador atribuiu 40% de peso ao R^2 obtido no treinamento e 60% ao R^2 obtido na fase de teste, conforme Equação 7.

$$R^2_{\text{Ponderado}} = 0.4 * R^2_{\text{Treinamento}} + 0.6 * R^2_{\text{Teste}}$$

Equação 7


Essa ponderação visa privilegiar modelos com maior capacidade de generalização (que consideram os dados não usados no treinamento da rede, simulando o uso em aplicações reais), reduzindo o risco de sobreajuste, uma condição comum no aprendizado de máquina, na qual o desempenho no treinamento é alto, mas se deteriora em dados não vistos. A escolha da proporção 40%-60% baseou-se em estudos da literatura (SANTOS et al., 2024; LUNARDI et al., 2025) e no fato de dar maior peso à capacidade de generalização (definida pela performance de teste), buscando um equilíbrio entre aprendizado eficaz e robustez preditiva. A Figura 8 apresenta o desempenho das RNAs com uma camada oculta, e a Figura 9 apresenta o desempenho das RNAs com duas camadas ocultas. O desempenho nessas figuras é definido pelo coeficiente de determinação (R^2), que, quanto mais próximo de 1, indica uma alta correlação entre os valores reais e os estimados pelo modelo de RNAs.

Figura 8. Avaliação do desempenho das RNAs com uma camada oculta.



Fonte: Própria autoria.

Figura 9. Desempenho das RNAs com duas camadas ocultas no a) treinamento, b) teste.



Fonte: Própria autoria.

A Figura 8 apresenta a variação do desempenho da rede em função do número de neurônios na camada oculta, tanto no conjunto de treinamento quanto no de teste, permitindo a comparação entre as diferentes configurações avaliadas.

Da Figura 8, é possível inferir que, ao usar redes com uma camada, são necessários pelo menos quatro neurônios para alcançar R^2 superior a 0,8 no treinamento, indicando boa capacidade de aprendizado (R^2 entre 0,8 e 1). Para as redes com duas camadas (Figura 9a), observou-se que são necessários 4 neurônios na primeira camada e 2 na segunda, para obter coeficientes de determinação superiores a 0,8 no treinamento. Ainda é possível inferir que não há uma regra

clara entre as performances de treinamento e de teste; ou seja, redes com boa capacidade de aprendizado não necessariamente terão boa capacidade de generalização.

As melhores performances obtidas segundo essa métrica são apresentadas na Tabela 5 para redes com uma camada oculta e na Tabela 6 para redes com duas camadas ocultas. As topologias/arquiteturas das redes neurais são definidas por [X-N1-Y] nas redes com uma camada e por [X-N1-N2-Y] nas redes com duas camadas, onde X refere-se ao número de neurônios na camada de entrada (sempre 6), N1 refere-se ao número de neurônios na primeira camada oculta (em algumas redes, a única), N2 é o número de neurônios na segunda camada e Y é o número de neurônios na camada de saída (sempre 1).

Tabela 5. Desempenho (RMSE e R^2) das seis redes, com uma camada oculta, de melhor performance.

Topologia	RMSE _{Treinamento}	RMSE _{Teste}	R^2 Treinamento	R^2 Teste	R^2 Ponderado
[6-20-1]	0,01591	0,02231	0,88285	0,76163	0,81012
[6-5-1]	0,01908	0,02199	0,83135	0,76857	0,79368
[6-18-1]	0,01502	0,02394	0,89553	0,72551	0,79352
[6-9-1]	0,01650	0,02453	0,87394	0,71199	0,77677
[6-4-1]	0,01951	0,02307	0,82382	0,74513	0,77660
[6-16-1]	0,02026	0,02282	0,80999	0,75057	0,77434

Fonte: Própria autoria.

Tabela 6. Desempenho (RMSE e R^2) das seis redes, com duas camadas ocultas, de melhor performance.

Topologia	RMSE _{Treinamento}	RMSE _{Teste}	R^2 Treinamento	R^2 Teste	R^2 Ponderado
[6-7-5-1]	0,01424	0,01781	0,90602	0,8481	0,87132
[6-6-10-1]	0,01657	0,01949	0,87184	0,81804	0,83996
[6-8-9-1]	0,01539	0,02061	0,89032	0,79656	0,83406
[6-10-8-1]	0,01438	0,02131	0,91419	0,78256	0,83121
[6-9-1-1]	0,01830	0,01960	0,84501	0,81615	0,82769
[6-16-1]	0,01377	0,02206	0,91218	0,76693	0,82503


Fonte: Própria autoria.

A análise dos resultados revela que as redes com duas camadas ocultas apresentaram desempenho superior, com valores de R^2 ponderado variando entre 0,82 e 0,87, enquanto as redes com uma única camada oscilaram entre 0,77 e 0,81. A topologia que apresentou o melhor desempenho global foi a [6-7-5-1], com R^2 ponderado de 0,87132, destacando-se pelo equilíbrio entre os valores obtidos no treinamento (R^2 de 0,906) e no teste (R^2 de 0,848).

No caso das redes com uma camada oculta, a melhor configuração foi a [6-20-1], que alcançou um R^2 ponderado de 0,81012. Ambos os modelos foram ajustados com taxa de aprendizado de 0,2, pesos sinápticos iniciais definidos em 1 e função de ativação logística, parâmetros selecionados para otimizar o desempenho e minimizar o risco de sobreajuste.


A seguir, são apresentados a distribuição dos resíduos (valores preditos subtraídos dos valores reais) e a dispersão entre os valores preditos e reais gerados pelos modelos de melhor desempenho para cada configuração-base das RNAs avaliadas no estudo. Os resultados estão ilustrados nas Figuras 10 e 11.

Figura 10. Performance da melhor RNA com uma camada oculta [6-20-1]: a) distribuição dos resíduos e b) dispersão entre valores reais e preditos.



Fonte: Própria autoria.

Figura 11. Performance da melhor RNA com duas camadas ocultas [6-7-5-1]: a) distribuição de resíduos e b) dispersão entre os valores reais e os preditos.



Fonte: Própria autoria.

A Figura 10a apresenta a distribuição dos resíduos da rede [6-20-1]. A rede apresentou R^2 de 0,883 no treinamento e R^2 de 0,762 no teste, evidenciando desempenho satisfatório para o aprendizado e generalização (R^2 acima de 0,75). A maior parte dos resíduos varia entre -0,04 e 0,04, com os valores preditos concentrados entre 0,10 e 0,25. Na Figura 10b, a dispersão entre valores reais e preditos reforça a qualidade do ajuste, com R^2 geral de 0,859. A maioria dos pontos se posiciona próxima à linha de identidade, especialmente entre 0,12 e 0,20, indicando boa precisão nesse intervalo, que concentra a maior quantidade de dados e fornece mais informações para descrever o índice de vazios.

Na Figura 11a, observa-se que a distribuição dos resíduos para a topologia [6-7-5-1] também está centrada em torno de zero, com dispersão ainda menor do que a da arquitetura anterior. O modelo alcançou $R^2 = 0,906$ no treinamento e $R^2 = 0,848$ no teste, demonstrando melhora no aprendizado e na capacidade de generalização, quando comparado à RNA de melhor desempenho com uma camada oculta [6-20-1].

Já na Figura 11b, a dispersão entre os valores reais e os preditos indica forte concentração ao longo da linha de identidade, com $R^2 = 0,895$. A sobreposição entre as linhas de identidade e de melhor ajuste no intervalo de 0,10 a 0,20 reforça o desempenho do modelo.

Com base nos resultados das análises de desempenho e nos gráficos de resíduos e de ajuste, definiu-se, no estudo, que a RNA de topologia [6-7-5-1], com duas camadas ocultas, apresentou o melhor desempenho geral, tanto no aprendizado do problema quanto na generalização. Por esse motivo, esse RNA define o modelo objeto de estudo da pesquisa, mapeando o índice de vazios do concreto em função o tipo de cimento “CTYPE”; o consumo de cimento, em kg/m^3 “CC”; o tipo de agregado graúdo “ATYPE”; o consumo total de agregados, em kg/m^3 “AC”; a taxa de substituição de agregado natural por RCD, em %, “TS”; a relação água-cimento “W/C”.

4 Análise de aplicabilidade do modelo proposto

Após o desenvolvimento do modelo preditivo do índice de vazios, utilizando redes neurais artificiais (RNA) com duas camadas ocultas, realizou-se mais um teste de generalização, agora acompanhado de uma avaliação comparativa da capacidade de generalização do modelo proposto em relação a formulações da literatura. Para isso, foram levantados mais dados, de concretos com diferentes relações água-cimento e materiais empregados como agregados.

A comparação com formulações da literatura foi conduzida com base no modelo proposto por Neville e Brooks (1998), reconhecido e utilizado na literatura técnica para a estimativa da

porosidade de concretos (Equação 8). A formulação foi utilizada neste estudo, pois permite estimar o índice de vazios a partir dos parâmetros do banco de dados. Outros modelos não foram empregados, pois exigiam parâmetros de entrada desconhecidos. O modelo, apresentado na Equação 8, relaciona a porosidade (P) aos parâmetros do traço, ao grau de hidratação e às massas específicas dos agregados.

$$P = \frac{\frac{w}{c} - 0.36 \alpha + \frac{A}{c}}{0.317 + \frac{1}{\gamma_a} \frac{a}{c} + \frac{1}{\gamma_b} \frac{b}{c} + \frac{A}{c}} \quad \text{Equação 8}$$

em que “A” o volume de ar inserido no corpo de proba, e “ α ” o grau de hidratação do cimento respectivamente.

De acordo com o modelo de Powers, adaptado por Jensen e Hansen (2001), a hidratação completa do cimento ocorre quando a relação água/cimento é igual ou superior a 0,42, pois, para cada grama de cimento, são necessários aproximadamente 0,23 g de água quimicamente ligada e 0,19 g de água de gel, totalizando 0,42 g. Com base nesse princípio, o grau de hidratação (α) pode ser estimado de forma simplificada pela Equação 9.

$$\alpha = \frac{w/c}{0,42} \quad \text{para } w/c \leq 0,42$$

$$\alpha = 1 \quad \text{para } w/c > 0,42$$

Equação 9

A Tabela 7 apresenta os traços dos concretos utilizados para a validação do modelo, juntamente com as massas específicas dos materiais constituintes, obtidas das fontes indicadas. Cabe destacar novamente que esses dados não foram utilizados nas fases de treinamento e de teste/validação das RNAs.

A Figura 12 apresenta os valores estimados do índice de vazios para cada amostra, considerando três abordagens distintas: dados experimentais, valores preditos pelo modelo gerado com RNA e os resultados obtidos pela Equação 8.

A Figura 13 apresenta os valores do erro absoluto para cada amostra, permitindo comparar o desempenho do modelo de RNA com o da formulação de Neville e Brooks (1998). A partir da Figura 13, observa-se que os maiores erros na estimativa do índice de vazios ocorreram com o uso da equação de Neville e Brooks (1998), o que reforça as limitações dessa abordagem em captar a complexidade do comportamento real do concreto. Para uma avaliação mais abrangente da precisão dos modelos, utilizou-se a métrica do Erro Absoluto Médio (MAE), amplamente

reconhecida por sua simplicidade e eficácia (NETO, 2012). Segundo Carmo e Silva (2023), o MAE é definido pela Equação 10.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i|$$


Equação 10

Tabela 7. Descrição dos dados dos concretos utilizados na aplicação do modelo.

Amostra	Fonte	Traço do concreto (C:A:B)	Relação W/C	Massa Específica da Areia (kg/m³)	Massa específica da brita (kg/m³)
1	Frotte et al. (2017)	1:2,9:3,16	0,645	2,63	2,74
2	Franchini, (2021)	1:2,36:2,64	0,6297	2,63	2,72
3	Ugioni; Santos, (2017)	1:3,13:3,38	0,57	2,61	3,04
4	Ugioni; Santos, (2017)	1:3,68:3,83	0,65	2,61	3,04
5	Pedrosa, (2012)	1:1,57:1,93	0,5	2,54	1,56
6	Pedrosa, (2012)	1:1,57:1,93	0,55	2,54	1,56
7	Pedrosa, (2012)	1:1,57:1,93	0,58	2,54	1,56
8	Meireles, (2005)	1:2,65:3,57	0,67	2,65	2,68
9	Meireles, (2005)	1:1,77:2,68	0,5	2,65	2,68
10	Meireles, (2005)	1:1,24:2,14	0,4	2,65	2,68


Fonte: Própria autoria.

Figura 12. Comparação entre os valores reais e preditos pelos modelos.



Fonte: Própria autoria.

Figura 13. Erro absoluto na determinação do índice de vazios com o modelo de RNA e a Equação 8.



Fonte: Própria autoria.

A análise dos resultados evidencia que o modelo proposto, baseado em RNAs, apresentou desempenho significativamente superior ao do método analítico de Neville e Brooks (1998), na estimativa do índice de vazios. Em praticamente todas as amostras, os valores preditos pela RNA mostraram-se mais próximos dos dados experimentais, indicando maior precisão do modelo.

Os erros absolutos confirmam essa tendência: enquanto o modelo analítico de Neville e Brooks (1998) apresentou maiores erros em diversas amostras (acima de 0,04), com destaque para as amostras 2, 3, 8, 9 e 10, a RNA apresentou erros baixos (inferiores a 0,02) e consistentes em todas as previsões, exceto na amostra 4, que, ainda assim, obteve erro inferior a 0,04. O valor do erro absoluto médio (MAE) para a RNA foi de 0,0090, em comparação com 0,0482 do modelo analítico, reforçando a superioridade da abordagem de aprendizado de máquina.

Os resultados confirmaram o desempenho do modelo de RNA na fase de teste/validação e reforçaram a capacidade preditiva, indicando que as incertezas de predição observadas na modelagem se mantêm em aplicações práticas, inclusive em concretos com composições variadas e com a presença de agregados de RCD. Sua aplicabilidade se destaca especialmente em contextos com limitações de recursos para ensaios laboratoriais ou na busca por agilidade na avaliação de diferentes traços.

5 Conclusões

O presente estudo aponta a viabilidade e a eficácia da aplicação de redes neurais artificiais na predição do índice de vazios em concretos com agregados de diferentes origens. A abordagem baseada em aprendizado de máquina mostrou-se capaz de integrar múltiplas variáveis de composição, incluindo o tipo de cimento (CTYPE), o consumo de cimento (CC), o tipo de agregado graúdo (ATYPE), o consumo total de agregados (AC), a taxa de substituição por resíduos de construção e demolição (TS) e a relação água/cimento (W/C), capturando a influência destes parâmetros sobre a porosidade.

Os resultados obtidos indicam o desempenho preditivo dos modelos desenvolvidos. A rede com uma única camada oculta apresentou coeficiente de determinação ponderado (R^2) de 0,81, enquanto a configuração com duas camadas ocultas alcançou R^2 de 0,87, o que demonstra que o aumento da profundidade da rede contribuiu para o aprimoramento das previsões. Em particular, a topologia [6-7-5-1] apresentou desempenho superior, com coeficiente de determinação individual de 0,89, além de melhor aderência à linha de identidade e de redução significativa dos resíduos. Destaca-se, ainda, que o modelo apresentou maior precisão na faixa de índice de vazios entre 0,10 e 0,20, intervalo crítico para a avaliação e a modelagem do comportamento do concreto.

A comparação com o modelo analítico de Neville e Brooks (1998) reforça a superioridade da abordagem de aprendizado de máquina, porém, para o banco de dados empregado neste trabalho. Enquanto o modelo baseado em RNA apresentou erro absoluto médio (MAE) de 0,009, o modelo analítico apresentou MAE de 0,048, evidenciando um ganho de precisão preditiva. Além de reproduzir com maior fidelidade os valores experimentais, a RNA demonstrou consistência ao longo de toda a faixa analisada, reforçando seu potencial como ferramenta para prever a porosidade do concreto.

A análise de importância das variáveis revelou que o tipo de cimento (CTYPE) foi o fator mais influente na previsão do índice de vazios, independentemente da topologia adotada. Esse resultado destaca o papel fundamental do ligante na formação da microestrutura do concreto e na definição de sua porosidade, particularmente em sistemas com incorporação de agregados reciclados. As demais variáveis, como o consumo de materiais, a relação água/cimento e a taxa de substituição, também contribuíram para o desempenho do modelo, evidenciando o caráter multifatorial do fenômeno.

Apesar dos resultados, algumas limitações devem ser reconhecidas. A base de dados foi construída a partir de diferentes fontes da literatura, o que implica variabilidade associada aos procedimentos experimentais, aos materiais e às condições de ensaio. Além disso, o modelo foi desenvolvido sem considerar outros fatores relevantes, como o uso de aditivos químicos, diferentes regimes de cura ou a incorporação de aditivos redutores de água.

Outro aspecto importante refere-se ao domínio de validade do modelo, que deve ser restrito aos intervalos de valores das variáveis utilizados no treinamento. As variáveis de entrada incluíram: o consumo de cimento (CC), variando entre 126,05 e 550,00 kg/m³; o consumo total de agregados (AC), entre 759,90 e 2474,50 kg/m³; a taxa de substituição de agregados naturais por RCD (TS), entre 0,00 e 1,00; a relação água/cimento (W/C), entre 0,27 e 1,02; além do tipo de cimento (CTYPE) e do tipo de agregado graúdo (ATYPE), representados como variáveis categóricas.

Nesse contexto, a aplicação do modelo fora desses intervalos pode resultar em extrapolações pouco confiáveis, uma vez que redes neurais artificiais têm capacidade limitada de generalização para além do espaço amostral utilizado no treinamento. Recomenda-se, portanto, que o modelo seja utilizado exclusivamente no domínio definido pelos dados disponíveis, especialmente considerando valores típicos próximos à faixa interquartil, onde a densidade de dados é maior e as previsões tendem a ser mais precisas.

Referencias

AHMAD, Shamsad.; AZAD, Abul Kalam. An exploratory study on correlating the permeability of concrete with its porosity and tortuosity. *Advances in Cement Research*, v. 25, n. 5, p. 288–294, 2013.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 9778: Argamassa e concreto endurecido – Determinação da absorção de água, índice de vazios e massa específica. Rio de Janeiro, 2018.

AMERICAN SOCIETY FOR TESTING AND MATERIALS. ASTM C642: Standard Test Method for Density, Absorption, and Voids in Hardened Concrete. West Conshohocken, 2009.

ATHAYDE. Avaliação da penetração de íons cloreto em concretos produzidos com escória de alto forno e agregados miúdos reciclados de resíduo de concreto fresco. 2020. Dissertação (Mestrado) – Universidade Federal de Minas Gerais, Belo Horizonte, 2020.

BARBOSA, Anderson Henrique; FREITAS, Marcílio Sousa da Rocha; NEVES, Francisco de Assis das. Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais. REM: Revista Escola de Minas, Ouro Preto, v. 58, n. 3, p. 247–255, jul./set. 2005. DOI: 10.1590/S0370-44672005000300011.

BATISTA, Bruna Caroline Campos; SILVA, Áquila Blanche Bastos Martins da; NOÉ, Amanda Freitas; LOPES, Raduan Krause; CHRISTOFORO, André Luis; ALMEIDA, Diego Henrique de. Influência da

adição de RCD misto na resistência à compressão e na porosidade de argamassa. *Revista Principia*, v. 59, n. 3, p. 934–948, 2022. DOI: 10.18265/1517-0306a2021id5005.

BELOTTI, Jonatas. Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles. 2019. Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná, Curitiba, 2019.

BERMOND, Camila; MIRANDA, Renato Billia; TECH, Adriano Rogério Bruno; MAUAD, Frederico Fábio. Preenchimento de falhas em dados de precipitação através de métodos tradicionais e por inteligência artificial. *Revista Brasileira de Climatologia*, v. 28, p. 187–207, 2021. DOI: 10.5380/abclima.v28i0.78539.

CARMO, Carlos; SILVA, Jessica. Aprendizado de máquina e prestação de serviços de armazenamento de dados: métricas para análise e validação de algoritmos previsores. *GETEC*, v. 12, 2023.

CARTUXO, Francisco; BRITO, Jorge de; EVANGELISTA, Luís; JIMÉNEZ, José Ramón; LEDESMA, Enrique F. Increased durability of concrete made with fine recycled concrete aggregates using superplasticizers. *Materials*, v. 9, n. 2, art. 98, 2016.

COSTA, Jose. Agregado reciclado de resíduos de construção e demolição: variabilidade e influência no comportamento mecânico do concreto. 2018. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 2018.

CUTLER, Adele; CUTLER Richard.; STEVENS, John. Random Forests. *Ensemble Machine Learning*. Springer, 2012. p. 157–175.

CYBENKOT. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, v. 2, 1989.

ESTOLANO, Victor; FUCALÉ, Stela; VIEIRA FILHO, José Orlando; GABRIEL, Diego; ALENCAR, Yuri. Avaliação dos módulos de elasticidade estático e dinâmico de concretos produzidos com agregados reciclados oriundos de resíduos de pré-fabricados de concreto. *Matéria* (Rio de Janeiro), v. 23, n. 1, e11974, 2018.

FILHO, Fabio. Avaliação da resistência à compressão e ao ataque por ácido sulfúrico de concretos com agregados graúdos reciclados de idades distintas. 2021. Dissertação (Mestrado) – Universidade Estadual do Norte Fluminense, Campo dos Goytacazes, 2021.

FRANCHINI, Caroline. Análise técnica do uso de agregado graúdo reciclado misto em concreto convencional. 2021. Trabalho de Conclusão de Curso – Universidade de Caxias do Sul, Caxias do Sul, 2021.

FROTTE, Camila; DI NUBILA, Clarisse Sophia Alejandra; NAGALLI, André; MAZER, Wellington; MACIOSKI, Gustavo; OLIVEIRA, Luna Ollin Steffen de. Estudo das propriedades físicas e mecânicas de concreto com substituição parcial de agregado natural por agregado reciclado proveniente de RCD. *Revista Matéria*, v. 22, n. 2, e11871, 2017. DOI: 10.1590/S1517-707620170002.0143.

GAMIL, Yaser. Machine learning in concrete technology: a review of current researches, trends, and applications. *Frontiers in Built Environment*, v. 9, 2023. DOI: 10.3389/fbuil.2023.1145591.

GERIN, Mayara. Comportamento de pilares mistos preenchidos com concreto de resíduos de concreto submetidos a compressão axial centrada. 2020. Dissertação (Mestrado) – Universidade Federal de Minas Gerais, Belo Horizonte, 2020.

Gomes, Bárbara; LEONEL, Antônio Carlos; LIMA, Vitor Augusto Lopes; ARAÚJO, Daniel de Lima. Avaliação da resistência e do módulo de elasticidade de concretos convencionais e autoadensáveis submetidos a altas temperaturas. *Revista Eletrônica de Engenharia Civil*, v. 17, n. 1, p. 63–83, 2021.

HAYKIN, S. *Redes neurais: princípios e práticas*. 2. ed. Porto Alegre: Bookman, 2001.

HERNÁNDEZ, Juan Diego; PEÑALOZA, Elena. Sobre el uso adecuado del coeficiente de correlación de Pearson. *Revista Facultad de Ciencias de la Salud*, v. 37, 2018.

HORNIK, Kurt. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, v. 4, p. 251–257, 1991.

JENSEN, Ole Mejlhede.; HANSEN, Per. Water-entrained cement-based materials I. Principles and theoretical background. *Cement and Concrete Research*, v. 31, n. 4, p. 647–654, 2001.

JÚNIOR. Desenvolvimento e análise de concreto com utilização de resíduos sólidos reciclados como agregado. 2021. Dissertação (Mestrado) – Universidade Federal do Ceará, Fortaleza, 2021.

LE, Ba-Anh; VU, Viet-Hung; SEO, Soo-Yeon; TRAN, Bao-Viet; NGUYEN-SY, Tuan; LE, Minh-Cuong; VU, Thai-Son. Predicting the compressive strength and the effective porosity of pervious concrete using machine learning methods. *KSCE Journal of Civil Engineering*, v. 26, n. 11, p. 4664–4679, 2022. DOI: 10.1007/s12205-022-1918-z. LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. DOI: 10.1038/nature14539.

LIMA, Mayara da Silva; CHAVES, Maria Thereza Rocha; AGUIAR, Marcos Fábio Porto de; FARIAS, Teresa Raquel Lima. Influência do resíduo de construção e demolição como agregado na produção de concreto para pavimentos permeáveis. *Revista Principia*, v. 62, 2024. DOI: 10.18265/2447-9187a2024id8566.

LOPEZ, Ana Maria. Distribuição de frequência. *SciELO Books*, p. 6–13, 2010.

MAIA, Poliana de Souza; SILVA JÚNIOR, Ladir Antônio da; SALLES, Pedro Valle; CARVALHO, Malheny Vitória Silva. Technical evaluation of structural concrete made with coarse aggregate from construction and demolition waste. *Research, Society and Development*, v. 11, n. 8, e45011830582, 2022. DOI: 10.33448/rsd-v11i8.30582.

MARMITTI, Benno Aluisio; BEZ, Anderson; DIDONE, Jorge Augusto; PACHECO, Thiago Loi; VALDAMERI, Cledison Zatta. Estudo comparativo de métodos para dosagem de concreto. In: *Congresso Técnico Científico da Engenharia e da Agronomia*. 2016.

MEIRELES, Priscila. Análise da influência da massa específica de agregados graúdos provenientes de resíduos de construção e demolição no desempenho mecânico do concreto. 2005. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2005.

MITCHELL, Tom. *Machine learning*. New York: McGraw-Hill, 1997.

MORAES, Andre; SANTOS, Danilo. Aplicação de redes neurais artificiais na previsão da resistência à compressão de concretos produzidos com agregados reciclados. *Revista AIDIS de Ingeniería y Ciencias Ambientales*, p. 1484–1501, 2022. DOI: 10.22201/iingen.0718378xe.2022.15.3.81651.

MORETTI, Jose. Sistema inteligente baseado nas redes neurais artificiais para dosagem do concreto. 2010. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 2010.

MOURA SANTOS, Hannah. Estudo laboratorial sobre os danos causados pelo broqueamento e retificação em corpos-de-prova testemunhos. 2006. Dissertação (Mestrado) – Universidade Federal de Pernambuco, Recife, 2006.

NEHME, Salem. The porosity of concrete and its analysis by neural networks. *ResearchGate*, 2000. Disponível em: <https://www.researchgate.net/publication/281069069>.

NETO, Aníbal Emiliano. Comparação de métodos de estimação de modelos de apreçamento de ativos. 2012. Dissertação (Mestrado) – Universidade de São Paulo, São Paulo, 2012.

NEVILLE, Adam; BROOKS, Jeffrey. *Concrete technology*. New York: Prentice Hall, 2018.

NOGUEIRA, Daniella; LIMA, Rafaela; GOMES Kiria. Influência do metacaulim para o tratamento do agregado graúdo reciclado de concreto. *Brazilian Journal of Development*, v. 6, n. 3, p. 15326–15339, 2020.

NUNES, Wesley Carlos. Influência do agregado graúdo reciclado de resíduos da construção predial nas propriedades do concreto fresco e endurecido. 2017. Dissertação (Mestrado) – Universidade Federal de Goiás, Goiânia, 2017.

OLIVEIRA, Marco Antônio Assis; FERREIRA, Marcelo Laédson Morato; SILVA JÚNIOR, Edmilson Roque da; ARAÚJO, Deividy Kaik de Lima; LIMA, Danylo de Andrade. Análise da substituição do agregado graúdo por RCD em concretos. 2023. DOI: 10.55449/conresol.6.23.vii-005.

PAIXÃO, Joelson. Redes neurais artificiais: estrutura, modelagem matemática e exemplo de aplicação. In: *Inovações Multidisciplinares na Engenharia*. Aurum Editora Ltda., 2025. p. 12–22. DOI: 10.63330/aurumpub.005-002.

PEDRO, Daniel; DE BRITO, Jorge; EVANGELISTA, Luis. Influence of the use of recycled concrete aggregates from different sources on structural concrete. *Construction and Building Materials*, v. 71, p. 141–151, 2014.

PEDROSA, Edson. Propriedades físico-mecânicas do concreto de cimento Portland contendo resíduo vítreo como agregado miúdo. 2012. Dissertação (Mestrado) – Instituto Federal do Maranhão, São Luís, 2012.

PIMENTEL, Pamela; BITTENCOURT, Felipe. Análise da resistência do concreto convencional com substituição parcial do agregado natural por agregado de polietileno tereftalato (PET) com uso de aditivo. 2018.

PIOVESAN, Jayne Carlos. Otimização multivariada da substituição de agregados de resíduos de construção e demolição em concreto. 2016. Dissertação (Mestrado) – Universidade Federal do Amazonas, Manaus, 2016.

RIVERA, Salvador. Breve introducción a la teoría de errores y la graficación. 2017.

ROSENBLATT . The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, n. 6, p. 386–408, 1958.

RUMELHART, David; HINTON, Geoffrey.; WILLIAMS, Ronald. Learning representations by back-propagating errors. *Nature*, v. 323, n. 6088, p. 533–536, 1986. DOI: 10.1038/323533a0.

SANTOS, Larissa Gabriela dos; FALCÃO, Isabela da Silva; FÉLIX, Emerson Felipe; PRADO, Lisiane Pereira. Predição do índice de vazios de concretos com RCD: proposição de modelo baseado em aprendizado de máquina e validação experimental. In: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2024. Anais [...]. 2024.

SILVA, Jessica. Comportamento sob altas temperaturas de concretos com agregados reciclados de concreto. 2017. Dissertação (Mestrado) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2017.

SILVA, Carla.; CAPUZZO, Valdirene. Evaluation of the durability of concretes produced with recycled concrete aggregates using the two-stage mixing approach. *Revista Materia*, v. 25, n. 1, 2020. DOI: 10.1590/s1517-707620200001.0882.

SILVA; SPATTI; FLAUZINO. *Redes neurais artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.

SILVA, Jamilly Alfano; SANTOS, Vinicius Daniel de Oliveira; VIANA, Danilo Fernandes; ARAÚJO, Raiane Sodrê de. Concreto reciclado: a importância de inserção de práticas sustentáveis para reduzir os

impactos ambientais e econômicos da construção civil. *Research, Society and Development*, v. 11, n. 17, e230111739180, 2022. DOI: 10.33448/rsd-v11i17.39180.

SOUZA, Rafael Eller; ASSIS, João Batista Santos; VIEIRA, Davi Henrique Tomé Kanno; GRANATO, Leonardo Carlos; ASSIS, Paulo Santos. Hidratação do concreto adicionando cinza da casca de café. In: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2023. São Paulo: IBRACON, 2023. p. 2291–2303. DOI: 10.5151/2594-5327-40402.

TEDESCO, Marina. Estudo da utilização de resíduo de casca cerâmica de microfusão no concreto em substituição ao agregado graúdo e miúdo natural. 2016. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

TENÓRIO, Jonathas. Avaliação de propriedades do concreto produzido com agregados reciclados de resíduos de construção e demolição visando aplicações estruturais. 2007. Dissertação (Mestrado) – Universidade Federal de Alagoas, Maceió, 2007.

UGIONI, Vinicius; SANTOS, Daine. Análise das propriedades mecânicas do concreto produzido com substituições parciais e totais dos agregados graúdos e miúdos por agregados reciclados. Criciúma: UNESC, 2017.

VIEIRA, Tiago; ALVES, André Vaz; BRITO, Jorge; CORREIA, João Pedro; SILVA, Rui Vasco Pacheco Santos. Durability-related performance of concrete containing fine recycled aggregates from crushed bricks and sanitary ware. *Materials & Design*, v. 90, p. 767–776, 2016.

ABORDAGEM INTEGRADA ENTRE MEFP E REDES NEURAIS ARTIFICIAIS PARA A MODELAGEM MESOESCALAR DO CONCRETO

Jairo O. F. Barreto^{a*} e Emerson F. Felix^b

^a Pós-Graduação em Engenharia Civil, Universidade Federal de Integração Latino-Americana (UNILA), Foz do Iguaçu, Brasil e-mail: jairobarretof@gmail.com

^b Departamento de Engenharia Civil, Faculdade de Engenharia e Ciências, Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Guaratinguetá 12516-410, Brasil e-mail: emerson.felix@unesp.br

Resumo

O comportamento mecânico do concreto é influenciado pela heterogeneidade de sua mesoestrutura, composta por matriz de argamassa, agregados graúdos e vazios. Embora a modelagem em mesoescala permita representar de forma mais realista os mecanismos de deformação e de transferência de tensões, a incorporação dos vazios em modelos numéricos ainda representa um desafio devido à complexidade de sua caracterização e de sua distribuição espacial. Neste contexto, este trabalho avalia abordagens integradas entre o Método dos Elementos Finitos com versão Posicional (MEFP) e Redes Neurais Artificiais (RNAs) para simular o comportamento mecânico do concreto em mesoescala. Inicialmente, foi realizada uma análise de referência, sem considerar os vazios, com o objetivo de avaliar a influência da distribuição granulométrica dos agregados sobre a resposta mecânica do material. Em seguida, foram investigadas duas estratégias para incorporação da porosidade: (i) representação indireta dos vazios por meio da penalização do módulo de elasticidade da matriz de argamassa, utilizando índices de vazios estimados por RNAs; e (ii) representação explícita dos vazios como descontinuidades geométricas na malha de elementos finitos. Os resultados mostraram que a desconsideração da porosidade leva à superestimação da rigidez do concreto, enquanto a inclusão dos vazios reduz significativamente o módulo de elasticidade equivalente e melhora a concordância com os resultados experimentais. Entre as estratégias avaliadas, a abordagem indireta apresentou maior eficiência, considerando custo computacional e desempenho, alcançando um erro percentual absoluto médio (MAPE) de 1,03%, enquanto a modelagem explícita dos vazios apresentou MAPE de 13,73%. Além disso, verificou-se que o aumento do tamanho dos agregados promove maior heterogeneidade dos campos mecânicos e reduz a rigidez equivalente do compósito. Como principal contribuição, o estudo demonstra que a integração entre elementos finitos e aprendizado de máquina constitui uma alternativa eficiente para incorporar os efeitos da porosidade em modelos mesoestruturais de concreto.

Palavras-chave: Modelagem numérica, rigidez, índice de vazios, elementos finitos.

1 INTRODUÇÃO

1.1 Contextualização

O concreto é um dos materiais mais utilizados na engenharia civil, sendo amplamente empregado em estruturas devido à sua resistência e durabilidade (MAZONI ; TABORDA ,2024). Este material é frequentemente considerado como um material homogêneo, sendo seu comportamento mecânico influenciado por sua natureza heterogênea composta por matriz de argamassa, agregados graúdos, zona de transição interfacial (ITZ) e vazios (WEI et al., 2025).

Essa heterogeneidade torna-se particularmente relevante em análises que envolvem deformação e fratura, nas quais os mecanismos de microfissuração, propagação de trincas e redistribuição de tensões dependem diretamente da interação entre as diferentes fases do material (MURSHIDA et al., 2023).. Nesse contexto, abordagens baseadas na modelagem em mesoescala têm sido amplamente utilizadas, uma vez que permitem representar explicitamente a microestrutura do concreto e capturar de forma mais realista os fenômenos físicos associados ao seu comportamento mecânico (THILAKARATHNA et al., 2020).

Na modelagem em mesoescala, o concreto é tipicamente representado como um compósito multifásico, no qual os agregados são inseridos na matriz de argamassa e separados pela zona de transição interfacial (BORGES et al. ,2017). Essa abordagem possibilita a análise da influência de parâmetros como distribuição granulométrica, forma dos agregados e propriedades mecânicas das fases na resposta global do material (RODRIGUES et al. ,2016). No entanto, a representação dos vazios ainda constitui um desafio relevante, uma vez que sua presença afeta diretamente a rigidez e a resistência do concreto, mas sua quantificação e distribuição são difíceis de determinar experimentalmente (WANG et al. ,2015a).

Estudos experimentais demonstram que o aumento da porosidade reduz significativamente a resistência mecânica do concreto. Segundo Forti et al. (2020), Li et al. (2023) e Zhu et al. (2025), para uma condição de tamanho de poros aproximadamente constante, a resistência à compressão axial diminui progressivamente com o aumento da porosidade, evidenciando a influência dos vazios na microestrutura do material.

Nesse contexto, Zhu et al. (2025) observaram reduções de resistência de até 34,02%, demonstrando o impacto significativo da porosidade no comportamento mecânico do concreto. De forma semelhante, Zhang et al. (2022a) verificaram que um aumento da porosidade de aproximadamente 8% resultou na redução da resistência à compressão axial de 54,4 MPa para 33,16 MPa.

De forma semelhante, Xu et al. (2024) também avaliaram a influência da variação da porosidade sobre o comportamento mecânico do concreto. Os autores observaram que a redução da porosidade de 25% para 15% resultou em um aumento médio de 35,9% na resistência à compressão. Em contrapartida, quando a porosidade aumentou de 15% para 25%, verificou-se uma diminuição da resistência mecânica e da durabilidade do material, com redução média de 9,64%.

Esses resultados demonstram que a porosidade exerce influência direta sobre o comportamento mecânico do concreto, evidenciando a importância de representar adequadamente os vazios em modelos numéricos e analíticos. Entretanto, muitos modelos analíticos ainda representam os vazios de forma simplificada, considerando apenas a porosidade média como parâmetro principal (AHMED et al., 2024; ZHU et al., 2025). Segundo Choren et al. (2013), a maioria das equações teóricas é baseada em microestruturas idealizadas, que frequentemente não representam adequadamente os materiais reais e suas aplicações práticas. Como consequência, parâmetros importantes, como a distribuição espacial dos vazios e sua interação com os constituintes do concreto, acabam sendo negligenciados, embora possam influenciar significativamente as propriedades elásticas e limitar a capacidade preditiva dos modelos numéricos (AHMED et al., 2024; VIEIRA et al., 2024).

Não obstante, além das abordagens numéricas e analíticas, existem também técnicas experimentais para a caracterização da porosidade em concretos por meio de ensaios físicos. Entre os métodos clássicos mais empregados destacam-se os ensaios de sorptividade, taxa inicial de sucção, saturação por vácuo e os ensaios de absorção por imersão e ebulição (WILSON et al., 1999).

Segundo a NBR 9778 (ABNT, 2005), o ensaio de absorção por imersão e ebulição consiste inicialmente na secagem completa da amostra de concreto em estufa até a obtenção de massa constante, determinando-se posteriormente sua massa seca. Em seguida, a amostra é submersa em água e submetida à ebulição por um período determinado. Após o resfriamento, realiza-se a medição da massa saturada do corpo de prova. Dessa forma, a diferença entre a massa saturada e a massa seca permite determinar a quantidade de água absorvida pelo concreto, possibilitando a estimativa do volume de vazios e, consequentemente, do índice de vazios do material (WILSON et al., 1999).

Embora estes ensaios ou técnicas padronizadas, a exemplo da ASTM C457 (ASTM, 2024), que se baseiam na travessia linear ou na contagem de pontos em seções planas de um corpo de prova, permitam avaliar a porosidade total bidimensional, mostraram-se insuficientes para

determinar a distribuição espacial tridimensional dos vazios de ar, pois não é apresentado o volume total (LYU et al., 2022). À medida que a ciência dos materiais evoluiu, foram desenvolvidos métodos mais avançados, tanto destrutivos quanto não destrutivos. Um dos métodos destrutivos utilizados é a porosimetria por intrusão de mercúrio (MIP), que permite extrair dados sobre a distribuição do tamanho dos poros, mas apresenta uma desvantagem conhecida como efeito garrafa de tinta e a possibilidade de danificar a estrutura dos poros (Rodríguez-Brito et al., 2025). Pelo qual para superar esta desvantagem foi implementado métodos não destrutivos como a Tomografia Computadorizada de Raios X (XCT ou Micro-CT) que permite avaliar o concreto num plano 3D ao gerar conjunto de dados volumétricos não destrutivos para determinar com exatidão a localização dos vazios (AHMED et al., 2024; LYU et al., 2022).

Considerando o avanço na metodologia destes procedimentos pode-se observar uma melhoria da precisão e da capacidade da análise espacial tridimensional do concreto, mas isto trouxe consigo um aumento considerável na complexidade porque é preciso ter maior conhecimento e tempo para fazer ensaios e análises com microscópico, além disso, tem-se um aumento nos custos associados aos ensaios (AHMED et al., 2024; LYU et al., 2022; RODRÍGUEZ-BRITO et al., 2025).


Diante desses desafios técnicos e econômicos, as pesquisas atuais propõem o uso de ferramentas numéricas para simular o comportamento físico-mecânico do concreto em diferentes escalas, com foco especial no Método dos Elementos Finitos (MEF). Além disso, considerando o avanço das técnicas de Aprendizado de Máquina, atualmente é recorrente o emprego de modelagem com dados para estimar ou mapear parâmetros físicos, químicos ou mecânicos dos materiais, incorporando estes valores nas simulações numéricas (FEI et al., 2023; PRAYOGO et al., 2020). Estudos recentes demonstram a eficácia dessas técnicas na predição do índice de vazios, reduzindo a dependência de métodos experimentais tradicionais e apresentando baixos níveis de incerteza (SANTOS et al., 2024). Assim, a integração de técnicas de Aprendizado de Máquina pode com o MEF pode facilitar a representação em mesoescala, incorporando, de forma mais realista e simplificada (sem a necessidade de realizar a caracterização físico-mecânica dos materiais constituintes do concreto), os efeitos da porosidade na resposta mecânica do material (WEI et al., 2025; ZHANG et al., 2022b).

1.2 Modelagem em mesoescala via MEF

Dependendo do tamanho do elemento estrutural a ser modelado, os modelos numéricos de concreto são tipicamente classificados em: microescala ($10^{-6} - 10^{-4}$ m), mesoescala

($10^{-3} - 10^{-1}$ m) e macroescala (maior que 10^0 m) (YANG et al., 2026). Na macroescala, o material é tratado como homogêneo, com propriedades médias equivalentes, o que torna essa abordagem adequada para análises estruturais globais. Já na mesoescala, o concreto é representado de forma explícita, considerando seus principais constituintes, como a matriz de argamassa, os agregados e a zona de transição interfacial (VIEIRA, 2021). Na microescala, o foco está na estrutura interna da pasta de cimento e na presença de poros (MURSHIDA et al., 2023).

Figura 1. Multiescala do Concreto.




Fonte: Editado de Baduge et al. (2025).

A mesoescala se destaca por permitir uma representação mais realista da heterogeneidade do concreto, sendo especialmente adequada para a análise de fenômenos como concentração de tensões, início de fissuras e sua propagação (THILAKARATHNA et al., 2020). Nesse nível, torna-se possível avaliar a influência da distribuição e das propriedades dos agregados, bem como da interface com a matriz, no comportamento global do material (WANG et al. (2015)). Para a modelagem numérica desses problemas, o Método dos Elementos Finitos é amplamente utilizado. Esse método consiste na discretização do domínio em elementos menores, com um número finito de pontos representativos do domínio, nos quais são calculados os campos de deslocamentos, tensões e deformações (AZEVEDO, 2003). Essa abordagem permite analisar problemas complexos, incluindo materiais heterogêneos e comportamentos não lineares. Na modelagem convencional de mesoescala, cada fase do concreto pode exigir uma malha própria ou uma discretização compatível entre a matriz, os agregados e o ITZ. Isso gera uma dificuldade importante: quanto maior o nível de detalhamento da geometria dos agregados e da zona de transição, maior tende a ser o número de elementos, nós e graus de liberdade do

problema (VIEIRA et al., 2024). Além disso, quando se exige compatibilidade entre as malhas das diferentes fases, a geração da malha torna-se mais complexa, especialmente quando os agregados são distribuídos aleatoriamente no domínio. Essa problemática aumenta o custo computacional e dificulta a criação de modelos com grande quantidade de partículas (RAMOS et al., 2021).

Como alternativa, o Método dos Elementos Finitos com versão Posicional (MEFP) permite representar sistemas compósitos utilizando uma estratégia de embutimento ou sobreposição de malhas (CODA; PACCOLA, 2009). Nessa formulação, a malha da matriz, por exemplo, a argamassa, é gerada inicialmente. Em seguida, são geradas malhas independentes para os agregados ou inclusões. Essas malhas são então sobrepostas à malha da matriz, sem necessidade de coincidência entre os nós das diferentes fases (MOURA, 2015; RAMOS et al., 2021). Segundo MOURA (2015) a formulação permite considerar a interação matriz-partícula sem coincidência entre as malhas e sem aumento do número de graus de liberdade, assumindo aderência perfeita entre as fases.

Figura 2. Comparação entre o MEF convencional e o MEFP.



Fonte: Própria autoria.

No MEFP, a principal diferença em relação ao MEF tradicional está na variável principal do problema. Enquanto no MEF clássico a formulação é geralmente escrita em função dos deslocamentos nodais, no MEFP a configuração atual do corpo é descrita diretamente pelas posições nodais (VIEIRA et al., 2021). Assim, as posições dos nós passam a ser as incógnitas

do problema. Essa característica facilita a consideração da não linearidade geométrica, uma vez que o equilíbrio é formulado diretamente na configuração deformada. Coda e Greco (2004) apresentaram uma formulação baseada na descrição posicional para a análise não linear geométrica de pórticos bidimensionais, sendo esta, uma das principais referências do MEFP.

Para compósitos, a estratégia consiste em escrever as posições nodais das partículas ou fibras em função das posições dos nós da matriz em que estão imersas. Dessa forma, quando a matriz se deforma, as partículas acompanham essa deformação por meio de relações cinemáticas, o que garante a aderência entre as fases. Felix (2022) explica que essa técnica permite inserir fibras ou partículas em qualquer posição do domínio, sem coincidência com os nós da matriz e sem acréscimo de graus de liberdade, tornando a simulação de sólidos compósitos mais rápida e eficiente.

Essa metodologia foi aplicada por Moura (2015) na análise bidimensional elástica de compósitos particulados com ênfase no concreto. A autora modelou a matriz de argamassa e os agregados como malhas independentes, utilizando elementos finitos triangulares. Em seus exemplos, a malha das partículas foi sobreposta à malha da matriz, sem necessidade de coincidência entre nós e elementos, para avaliar a influência da geometria, da fração volumétrica e das propriedades dos agregados sobre o módulo de elasticidade do concreto.

Além de Moura (2015), Felix (2022) também utilizou formulações baseadas no MEFP para modelagem do concreto em mesoescala. Em sua tese, o concreto foi representado como um compósito, com matriz de argamassa e agregados graúdos, e a técnica de embutimento foi empregada para representar as partículas imersas na matriz. O autor também destaca aplicações anteriores da metodologia em Coda e Paccola (2008), Paccola e Coda (2016), Coda e Paccola (2011) e Felix (2022).

Portanto, o MEFP apresenta-se como uma alternativa eficiente para a modelagem de mesoescala do concreto, principalmente quando se deseja representar agregados ou inclusões distribuídas aleatoriamente (FELIX, 2022; MOURA, 2015). A principal vantagem da técnica é permitir a sobreposição de malhas independentes, mantendo a interação entre as fases por relações cinemáticas e reduzindo a complexidade associada à geração de malhas compatíveis (CODA E PACCOLA, 2008, 2009). Essa característica é particularmente relevante para modelos de concreto em mesoescala, nos quais a distribuição, a geometria e a rigidez dos agregados influenciam a resposta mecânica global do material (RAMOS et al., 2021).

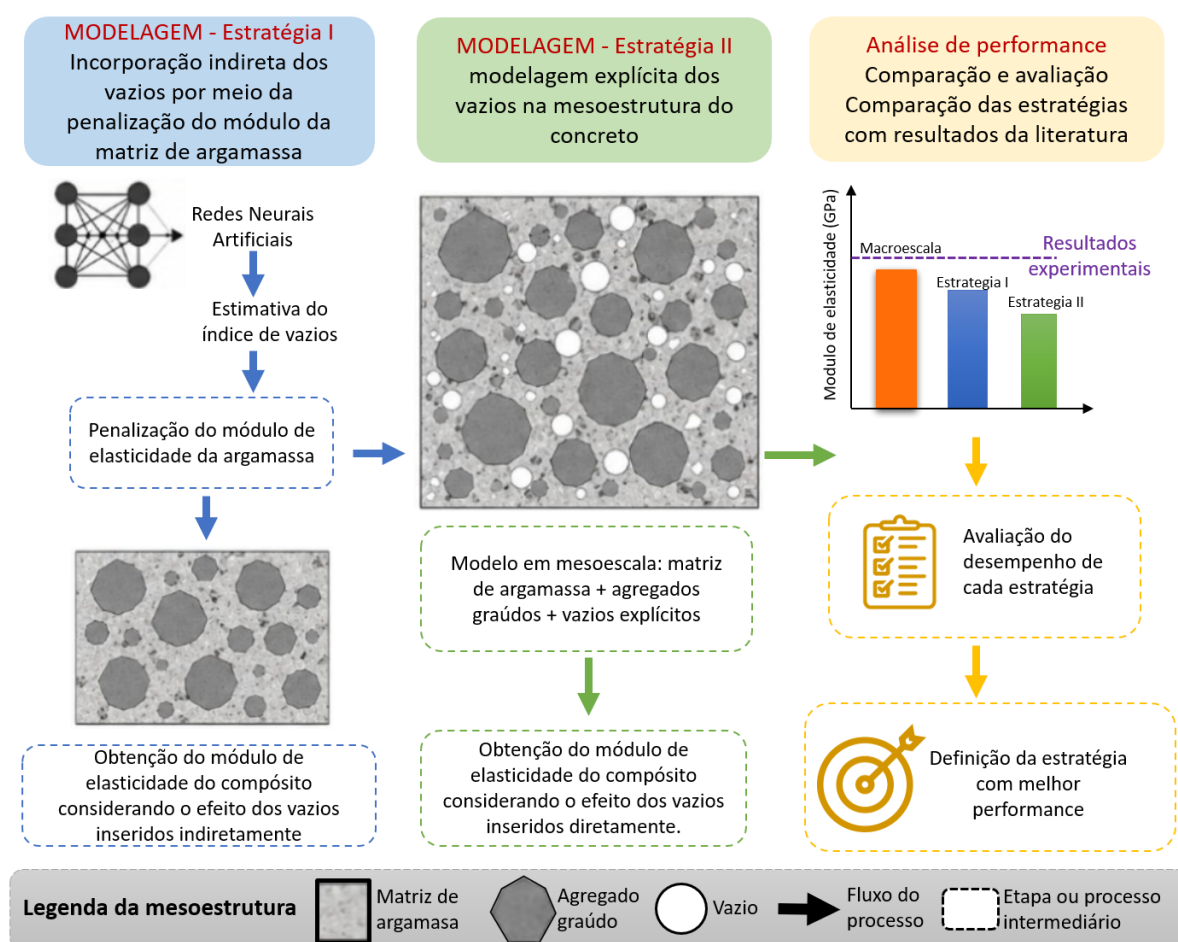
Diante disso, o presente trabalho tem como objetivo avaliar estratégias numéricas para representar o comportamento mecânico do concreto em mesoescala, integrando o MEFP a um modelo preditivo do índice de vazios do material, baseado em Redes Neurais Artificiais

(RNAs). Para isso, são investigadas duas estratégias de representação do compósito: (i) incorporação indireta dos vazios por meio da penalização do módulo de elasticidade da argamassa, utilizando um índice de vazios estimado pelo modelo proposto com RNAs (estratégia numérica I); e (ii) modelagem explícita dos vazios na mesoestrutura do concreto, considerando elementos finitos representativos dos poros (estratégia numérica II).

2 METODOLOGIA

Considerando o objetivo do trabalho, de avaliar estratégias de representação em mesoescala do concreto e, em especial, o acoplamento de um modelo de predição do índice de vazios, baseado em RNAs, com o MEF versão Posicional, na Figura 3 é apresentado um esquema que ilustra os principais processos e etapas metodológicas adotados.

Figura 3. Representação dos principais processos adotados na pesquisa.



Fonte: Própria autoria.

A metodologia divide-se em quatro etapas principais: (i) modelagem inicial do comportamento do concreto, sem considerar vazios, com foco na avaliação da influência da geometria e da distribuição das partículas representativas do concreto; (ii) modelagem do

concreto em mesoescala com a consideração da estratégia numérica II, com incorporação indireta dos vazios; (iii) modelagem com estratégia numérica II, com a representação dos vazios por elementos finitos; (iv) avaliação de performance das estratégias. Na sequência, cada etapa é detalhada, com considerações sobre as modelagens e os procedimentos metodológicos.

2.1 Dados do concreto de referência para as simulações numéricas

Os dados experimentais utilizados nessa etapa são provenientes de campanha experimental desenvolvida pelo grupo de pesquisa DASMAE, com a caracterização dos materiais, a produção dos concretos e os testes realizados por Maria Julia Alves, aluna envolvida em pesquisa de Iniciação Científica na UNESP-FEG. Inicialmente, foi disponibilizado o traço-base de um concreto de classe de resistência C25, contendo as proporções dos materiais constituintes utilizadas na dosagem do compósito. A Tabela 1 apresenta os materiais empregados, bem como suas respectivas quantidades e frações mássicas.

Tabela 1. Traço Base Concreto C25.


Material	Quantidade [Kg/m³]	Fração mássica [%]
Cimento	353,96	14,98
Areia média	800,44	33,88
Brita 1	1023,68	43,33
Água	184,19	7,79

Fonte: Própria autoria.

Após a definição do traço, também foram fornecidas as proporções granulométricas dos agregados empregados no concreto. O agregado graúdo empregado corresponde a uma brita de origem gnáissica (gnaisse), classificada como brita 1, com dimensão máxima característica de 19 mm. A Figura 4 apresenta a curva granulométrica do agregado utilizado, indicando a distribuição das partículas em função das aberturas das peneiras.

Além das informações sobre a composição do concreto, foram disponibilizados os resultados experimentais de tensão e deformação obtidos a partir de dois ensaios mecânicos realizados em corpos de prova. A partir das curvas tensão-deformação fornecidas, foram determinados módulos de elasticidade de 28,40 GPa e 26,40 GPa para os respectivos ensaios, resultando em um módulo de elasticidade médio de 27,40 GPa. Esse valor foi posteriormente utilizado como referência para a calibração e validação dos modelos numéricos desenvolvidos neste trabalho.

Figura 4. Curva Granulométrica -Brita 1.



Fonte: Própria autoria.

2.2 Análise inicial - influência da distribuição das partículas dos agregados

A primeira simulação numérica teve como objetivo avaliar a influência do tamanho característico dos agregados graúdos e sua distribuição no módulo de elasticidade do concreto em mesoescala, sem considerar a incorporação dos vazios. Segundo Neto et al. (2023), o módulo de elasticidade do concreto é fortemente influenciado pelas características dos agregados, especialmente pelo tamanho característico, teor e natureza mineralógica. Os autores demonstram experimentalmente que variações no diâmetro máximo do agregado graúdo alteram o nível de microfissuração na zona de transição interfacial, afetando diretamente a rigidez global do material. Observou-se ainda que concretos produzidos com agregados de maior rigidez e diferentes dimensões apresentaram variações significativas no módulo de elasticidade, evidenciando o papel do agregado como fase dominante no comportamento elástico do concreto (MOURA, 2015).


A utilização de agregados com geometria poligonal em modelos de mesoescala é amplamente adotada na literatura como uma alternativa à idealização circular, permitindo uma representação mais realista dos agregados graúdos (VIEIRA et al., 2024; WEI et al., 2025). Nesse sentido, Zheng et al. (2023) empregaram agregados representados por polígonos convexos em modelos bidimensionais, demonstrando que a forma geométrica dos agregados exerce influência significativa sobre a distribuição de tensões e o comportamento mecânico do concreto.

De forma semelhante, Rodrigues et al. (2016) adotaram a representação dos agregados por polígonos, evidenciando que essa abordagem permite considerar diferentes morfologias geométricas no modelo, mantendo um equilíbrio entre representatividade física e eficiência computacional. Com base nessas abordagens, neste trabalho, os agregados da Estratégia I foram representados por polígonos regulares do tipo pentágono, definidos no interior dos diâmetros

característicos adotados, de modo a garantir consistência geométrica com a granulometria do material.

Assim, a partir da curva granulométrica do agregado graúdo (Figura 4), identificou-se que a maior abertura de peneira considerada corresponde a 19 mm, adotada como o diâmetro máximo de referência do agregado. Com base nesse valor, foram definidos os diâmetros característicos D_{25} , D_{50} , D_{75} e D_{100} , correspondentes a 25%, 50%, 75% e 100% do diâmetro máximo, respectivamente. A Figura 5 apresenta a geometria definida para a representação dos agregados neste estudo, na qual se decidiu utilizar elementos poligonais com cinco faces e cinco nós. Para a definição das dimensões, definiu-se a geometria sempre considerando um polígono circunscrito com o diâmetro característico, e os valores obtidos para D_{25} (4,75 mm) e D_{50} (9,5 mm) coincidem com as aberturas reais das peneiras utilizadas na caracterização granulométrica do material, conferindo maior representatividade física aos diâmetros adotados. Para os demais casos, adotaram-se D_{75} de 14,25 mm e D_{100} de 19 mm.

Figura 5. Diâmetros adotados.




Fonte: Própria autoria.

Com base na composição experimental do concreto (Tabela 1), manteve-se constante, nos modelos numéricos, o volume de agregado de 43,3%, permitindo avaliar exclusivamente os efeitos da dimensão e da distribuição granulométrica sobre o comportamento mecânico do material.

A distribuição dos agregados foi realizada por meio de um código computacional desenvolvido em Python, no qual a geração das partículas considera a aleatoriedade da configuração inicial. Nesse código, cada partícula é representada por um elemento de partícula discretizado por meio de cinco elementos finitos triangulares com aproximação cúbica, contendo 31 nós e 62 graus de liberdade (Figura 6), o que permite uma descrição adequada da geometria das partículas no modelo numérico.

Figura 6. Elementos finitos de chapa para representação dos agregados.




Fonte: Própria autoria.

Com o auxílio desse código computacional, realizou-se a distribuição dos agregados no interior de uma área bidimensional de 10×10 cm, correspondente ao domínio da matriz adotada para representar o elemento de concreto. Nessa região, procedeu-se à geração e ao posicionamento aleatório das partículas de agregado, respeitando os parâmetros geométricos previamente definidos.

Para a modelagem inicial, na qual se investiga a influência da dimensão e da distribuição dos agregados, foram analisados quatro casos em que variou apenas o diâmetro dos agregados, e todos os agregados apresentavam as mesmas configurações e dimensões (D_25, D_50, D_75 e D_100). A Figura 7 apresenta a distribuição dos agregados utilizados nas simulações.


Para avaliar o efeito da distribuição não padronizada das partículas, foi considerada uma configuração denominada D_misto, na qual a distribuição dos agregados não se baseia em um único tamanho característico, mas sim é definida pela curva granulométrica experimental apresentada anteriormente (Figura 4). Nessa abordagem, a geração das partículas contempla simultaneamente diferentes classes de tamanho, permitindo representar de forma mais fiel a distribuição granulométrica real do material (Figura 8).

Figura 7. Distribuição dos agregados com dimensões fixas.



Fonte: Própria autoria.

Figura 8. Distribuição dos agregados para a configuração D_misto.



Fonte: Própria autoria.

Para essa configuração, adotaram-se os diâmetros equivalentes e as respectivas proporções associadas às peneiras com aberturas nominais de 2,36 mm, 4,75 mm, 9,5 mm, 12,5 mm e 19 mm, conforme indicado pela curva granulométrica. Dessa forma, a distribuição das partículas no interior da chapa de análise reflete diretamente a contribuição relativa de cada fração granulométrica presente no agregado. Assim como nas demais análises, manteve-se constante o volume total de agregado, fixado em 43,3%, de modo a assegurar a comparabilidade entre as diferentes configurações estudadas e isolar o efeito da variação granulométrica.

Considerando as cinco configurações de modelagem e que o polígono utilizado para a representação de um agregado possui cinco elementos finitos triangulares com ordem cúbica de aproximação, a Tabela 2 apresenta a quantidade de elementos finitos e o número de nós representativos destes.

Tabela 2. Parâmetros da discretização dos agregados graúdos para cada cenário de modelagem.

Classe de concreto	Caso	Nº de nós	Nº de elementos
C25	D_25	14200	1420
	D_50	3550	355
	D_75	1550	155
	D_100	850	85
	D_ misto	3000	300

Fonte: Própria autoria.

2.2.1 Definição do módulo de elasticidade dos agregados e da matriz de argamassa

Para a simulação numérica em mesoescala, é necessário definir o módulo de elasticidade de cada fase do compósito. O módulo de elasticidade do agregado graúdo foi definido com base em estudos experimentais que avaliam a influência da composição mineralógica dos agregados sobre o módulo de elasticidade do concreto. Trabalhos experimentais demonstram que a rigidez do agregado graúdo exerce influência direta no comportamento deformacional do concreto, sendo fortemente dependente da sua origem geológica e mineralógica (VASCONCELLOS, 2018).

Em particular, o estudo conduzido por Farias et al. (2018) avaliou concretos produzidos com agregados graúdos de diferentes composições mineralógicas, incluindo rochas ígneas, sedimentares e metamórficas, evidenciando que agregados de maior rigidez resultam em concretos com maiores valores de módulo de elasticidade. Para agregados de origem metamórfica, como o gnaiss, são reportados valores de módulo de elasticidade específicos na

faixa de 40 a 70 GPa (Tabela 3). Considerando essa faixa e visando representar de forma realista o comportamento mecânico do agregado graúdo utilizado neste estudo, adotou-se um valor médio de 55 GPa para o módulo de elasticidade do agregado de gnaíse.

Tabela 3. Módulo de elasticidade de agregados com diferentes composições mineralógicas.


Tipo de rocha	Módulo de elasticidade (GPa)
Arenito	20–40
Basalto	60–100
Calcário	30–50
Gnaíse	40–70
Granito	40–70

Fonte: Farias et al. (2018)

Definidas as propriedades mecânicas dos agregados graúdos, procedeu-se à compatibilização dessas propriedades com a matriz de argamassa, visando representar adequadamente o comportamento mecânico global do concreto em mesoescala. Para essa etapa, tornou-se necessário determinar o módulo de elasticidade da argamassa, tendo como referência o módulo de elasticidade equivalente do compósito obtido experimentalmente, de 27,40 GPa e do agregado de 55 GPa. Para a determinação do módulo de elasticidade da argamassa, utilizou-se uma abordagem indireta, tendo como referência os módulos de elasticidade do material compósito e do agregado graúdo. Essa abordagem fundamenta-se na teoria da elasticidade aplicada a materiais compósitos, na qual diferentes modelos de homogeneização (Figura 9) são empregados para relacionar as propriedades mecânicas das fases constituintes ao comportamento global do material.

Entre os modelos clássicos utilizados para esse fim, destacam-se os modelos de Voigt e Reuss, que representam, respectivamente, os limites superior e inferior teóricos do módulo de elasticidade efetivo de um material compósito. O modelo de Voigt baseia-se na hipótese de deformação uniforme em todas as fases, enquanto o modelo de Reuss assume a uniformidade das tensões. Esses modelos são amplamente utilizados como referências teóricas para a análise do comportamento elástico do concreto, servindo como limites para a validação de formulações mais realistas (ZHOU et al., 2025).

Figura 9. Modelos reológicos para a representação de compósitos.



Fonte: Felix (2018).

Considerando que os modelos de Voigt e Reuss tendem a superestimar ou subestimar o comportamento real do concreto, têm sido propostas na literatura formulações intermediárias. Dentre elas, o modelo de Hirsch combina ponderadamente as hipóteses de Voigt e Reuss, apresentando boa capacidade de representar o módulo de elasticidade do concreto como um material bifásico composto por matriz e agregados, conforme demonstrado por Gidrão et al. (2023). No mesmo estudo, também é discutido o modelo micromecânico de Hansen, no qual o agregado é tratado como uma inclusão elástica embutida na matriz contínua. Essa abordagem permite uma representação mais refinada da interação entre as fases constituintes do concreto, proporcionando uma descrição mais realista do seu comportamento elástico em comparação às hipóteses extremas adotadas pelos modelos de Voigt e de Reuss.

O modelo de Couto, por sua vez, consiste em uma formulação analítica aplicada ao concreto que busca representar o módulo de elasticidade efetivo a partir das propriedades individuais das fases e de suas proporções volumétricas. Abordagens dessa natureza, baseadas na teoria do meio efetivo, têm sido empregadas em estudos recentes para prever o módulo de elasticidade do concreto e determinar, inversamente, as propriedades da matriz quando o módulo global do compósito é conhecido (MAZONI; TABORDA, 2024).

Dentre esses modelos, optou-se pelo modelo de Reuss para determinar o módulo de elasticidade da matriz de argamassa. A escolha do modelo de Reuss justifica-se por representar o limite


inferior teórico do módulo de elasticidade efetivo, assumindo a condição de uniformidade de tensões entre as fases constituintes (PIANEZZER et al., 2017).

No âmbito deste estudo, adotaram-se, para o agregado graúdo, um módulo de elasticidade de 55 GPa e uma proporção volumétrica da matriz de argamassa de 65,7%. Com base nesses parâmetros, o modelo de Reuss foi aplicado de forma inversa para determinar o módulo de elasticidade da matriz de argamassa, resultando em 22,097 GPa. Esse valor foi adotado como propriedade mecânica da matriz nos modelos numéricos.

2.2.2 Condições de contorno na modelagem com sobreposição das malhas via MEFP

A matriz de argamassa utilizada nas simulações foi representada por uma chapa retangular com dimensões de 10 cm por 10 cm. O domínio foi discretizado de forma estruturada, com 800 elementos finitos triangulares e aproximação cúbica, totalizando 3721 nós. O nível de refinamento da malha foi definido em função da dimensão máxima do agregado graúdo imerso no concreto, assegurando discretização adequada para a correta representação da interação mecânica entre a matriz de argamassa e os agregados, previamente modelados com geometria poligonal de cinco faces, conforme a Figura 10.

Figura 10. Modelagem em mesoescala: matriz de argamassa, agregados e modelo final discretizado.



Fonte: Própria autoria.

As malhas correspondentes à matriz de argamassa e aos agregados, bem como suas respectivas características geométricas e mecânicas, foram inseridas em um programa computacional destinado à realização de análises mecânicas de modelos de concreto em mesoescala.

A partir dessas informações, o código realiza a compatibilização entre as diferentes fases do modelo por meio do MEFP, permitindo representar, de forma conjunta, o comportamento mecânico da matriz e dos agregados no domínio numérico analisado. Dessa forma, as malhas

das diferentes fases passam a atuar de forma integrada durante o processo de análise numérica, possibilitando a avaliação da interação mecânica entre os agregados e a matriz de argamassa ao longo da aplicação do carregamento. Além disso, essa abordagem permite representar explicitamente a heterogeneidade do concreto em mesoescala, considerando separadamente as propriedades mecânicas de cada fase do material.

Assim, na modelagem inicial, considerou-se a aplicação de uma força nodal equivalente na face superior do domínio, de modo a gerar uma tensão média de 5 MPa. Esse carregamento foi aplicado de forma incremental, em cinco etapas sucessivas de 1 MPa cada. A partir desse procedimento, foram realizadas simulações independentes para os conjuntos D_25, D_50, D_75, D_100 e D_misto. Para cada modelo, foram definidos nove pontos de análise distribuídos ao longo da chapa, utilizados para avaliação dos deslocamentos, das deformações e do módulo de elasticidade, conforme a Figura 10.

2.3 Modelagem com Estratégia I – incorporação de vazios por penalização da matriz

Diversos estudos investigaram a influência da porosidade nas propriedades mecânicas de materiais frágeis e porosos, demonstrando que o aumento da fração volumétrica de vazios reduz significativamente a rigidez do material (CHOREN et al., 2013; MICHELENA, 2013; PHANI; NIYOGI, 1987). Segundo Choren et al. (2013), materiais porosos podem ser interpretados como compósitos bifásicos, constituídos por uma fase sólida e outra correspondente aos vazios, cuja rigidez pode ser considerada nula.

Dentre as abordagens propostas na literatura para descrever a influência da porosidade no módulo de elasticidade de materiais porosos, encontra-se a formulação apresentada por Spriggs (1961), na qual o módulo de elasticidade é expresso em função da porosidade por meio de uma relação exponencial, conforme Equação 1, em que (E) representa o módulo de elasticidade do material poroso, (E_0) corresponde ao módulo de elasticidade do material sólido sem poros, (P) representa a fração volumétrica de porosidade e (b) é uma constante associada à microestrutura do material. Essa relação foi aplicada pelo autor a materiais cerâmicos policristalinos porosos.

$$E = E_0 e^{-bP} \quad \text{Equação 1}$$

Posteriormente, diferentes modelos foram desenvolvidos com o objetivo de representar melhor o comportamento mecânico de materiais porosos em uma faixa mais ampla de porosidade. Entre essas abordagens, destaca-se o modelo proposto por Phani e Niyogi (1987), que introduz uma relação semiempírica para descrever a dependência do módulo de elasticidade em função da

porosidade de sólidos frágeis porosos, conforme a Equação 2, em que (a) e (n) são constantes relacionadas à geometria de empacotamento das partículas e à morfologia da estrutura de poros do material. De acordo com os autores, o parâmetro (n) está associado à conectividade e à forma dos poros, enquanto o parâmetro (a) está relacionado à geometria de empacotamento da microestrutura do material.

$$E = E_0(1 - aP)^n \quad \text{Equação 2}$$

Ademais, Choren et al. (2013) destacam que diversas relações para materiais porosos decorrem da aplicação da regra das misturas, resultando em expressões simplificadas, como a Equação 3.

$$E = E_0(1 - P) \quad \text{Equação 3}$$

Diante do exposto, para a Estratégia I, os vazios não foram explicitamente representados na geometria da mesoestrutura. Em vez disso, seu efeito foi incorporado indiretamente por meio da modificação das propriedades mecânicas da matriz de argamassa. O módulo de elasticidade efetivo da argamassa, utilizado nas simulações numéricas com a Estratégia I, é definido pela Equação 4, em que (E_{arg}^*) é o módulo de elasticidade penalizado da argamassa, (E_{arg}) é o módulo de elasticidade da argamassa sem considerar os vazios e o (IV) corresponde ao índice de vazios estimado pelo modelo de redes neurais.

$$E_{arg}^* = E_{arg}(1 - IV) \quad \text{Equação 4}$$

Para a definição do módulo da argamassa penalizada, determina-se o índice de vazios do compósito por meio de um modelo preditivo baseado em Redes Neurais Artificiais (RNA), previamente desenvolvido por Barreto e Félix (2025). O modelo foi elaborado a partir de 199 amostras experimentais coletadas da literatura, abrangendo concretos convencionais e concretos com agregados de diferentes origens. Como variáveis de entrada, foram considerados parâmetros relacionados à dosagem do concreto, incluindo o tipo e a quantidade de cimento, o tipo e a quantidade de agregado, a relação água/cimento e a taxa de resíduos empregados como agregados graúdos.

Com base nos resultados da modelagem e validação, o modelo baseado em RNAs de melhor desempenho foi concebido com uma camada de entrada de 6 neurônios (conforme a Tabela 4), duas camadas ocultas (com 7 e 5 neurônios) e uma camada de saída para predição do índice de

vazios (IV). Com este modelo, pode-se determinar o índice de vazios do concreto simulado de classe de resistência C25, com base nos dados apresentados na Tabela 1, cujo resultado foi de 9,15% (IV). As entradas empregadas para prever o índice de vazios também são apresentadas na Tabela 4.

Tabela 4. Parâmetros de entrada do modelo de redes neurais.

Variável/Parâmetro	Unidade	Valor de entrada do C25
Tipo de cimento (CTYPE)	-	CPV=1
Quantidade de cimento (CC)	Kg/m ³	353,96
Tipo de agregado (ATYPE)	-	natural=0
Quantidade de agregado (AC)	Kg/m ³	1824.12
Substituição de agregado natural por RCD (TS)	%	0
Relação água-cimento (W/C)	-	0,52

Fonte: Própria autoria.

Após a determinação do índice de vazios, procedeu-se à penalização do módulo de elasticidade da matriz de argamassa, conforme a Equação 4. A partir da aplicação dessa relação, obteve-se um módulo de elasticidade efetivo da argamassa de 17,89 GPa.

Para as simulações numéricas do concreto, utilizando a Estratégia I, mantiveram-se as mesmas configurações granulométricas da simulação inicial. Porém, definiu-se que as simulações seriam realizadas com duas representações dos agregados, utilizando os cenários D_50 e D_misto. Esses cenários foram utilizados de forma a considerar uma representação em que todos os agregados possuem apenas um diâmetro e outra em que o diâmetro varia conforme as características da curva granulométrica. Destaca-se que a única diferença entre as simulações iniciais e a que emprega a estratégia I reside na incorporação do efeito dos vazios, por meio da penalização da matriz de argamassa.

2.4 Modelagem com Estratégia II – representação dos vazios com elementos finitos

Para a simulação numérica com a Estratégia II, mantiveram-se as configurações de representação dos agregados adotadas na Estratégia I, correspondentes aos casos D_50 e D_misto. Essa escolha teve como objetivo garantir que as diferenças observadas nos resultados fossem atribuídas exclusivamente à forma de tratar os vazios na modelagem.

Da mesma forma que na Estratégia I, o índice de vazios utilizado corresponde ao valor predito pelo modelo baseado em RNAs, que, para o C25, foi de 9,15%. Para a modelagem, manteve-se constante a fração volumétrica de vazios no compósito, o que possibilitou uma comparação direta entre as estratégias analisadas.

No que se refere à representação dos vazios, diversos estudos têm investigado a modelagem em mesoescala, considerando sua forma, dimensão e distribuição espacial. Wang et al. (2015b) representaram os vazios como inclusões de geometria circular ou elíptica, com diâmetros entre 2 e 4 mm, distribuídas aleatoriamente na matriz de argamassa. De forma complementar, Xu e Huang (2017) adotaram vazios circulares de dimensões menores, na faixa de 1 a 2 mm, também distribuídos aleatoriamente. Já Zhang et al. (2022b) consideraram uma faixa mais ampla de tamanhos, com vazios variando de 0 a 4 mm, sendo a maior parte concentrada em dimensões intermediárias.

No trabalho de Koopas et al. (2023), os vazios foram definidos como inclusões de geometria circular distribuídas aleatoriamente na matriz de argamassa, uma abordagem semelhante à adotada por Xu e Huang (2017). Entretanto, ao analisar a implementação numérica desses modelos, observa-se que a representação dos vazios no método dos elementos finitos não é contínua, pois seus contornos são definidos pela discretização da malha, o que, na prática, resulta em geometrias poligonais.


Sabendo disso, neste trabalho os vazios foram representados diretamente como geometrias poligonais, adotando-se um intervalo de diâmetros entre 1 mm e 4 mm, de modo a abranger as faixas típicas reportadas na literatura. Na Figura 11, apresenta-se a geometria adotada para os vazios, considerando dimensões representativas de 1 mm e 4 mm.

Segundo Zhang et al. (2022b), os poros encontram-se distribuídos aleatoriamente na matriz de argamassa e apresentam tamanhos em múltiplas escalas, variando da microescala à macroescala e, em geral, menores que os agregados. O autor também destaca que, mesmo quando os vazios são representados por geometrias poligonais, a distribuição espacial dessas discontinuidades influencia significativamente o comportamento mecânico do concreto.

Com base nessas considerações, os vazios foram distribuídos aleatoriamente na matriz de argamassa e representados por geometrias poligonais equivalentes, a fim de garantir compatibilidade com o processo de discretização do modelo de elementos finitos. Na Figura 12, apresenta-se a mesoestrutura gerada.


Para a simulação dos compósitos na Estratégia II, foram definidos os módulos da matriz de argamassa e dos agregados. Para as fases sólidas, correspondentes à argamassa e aos agregados, adotaram-se os mesmos valores de módulo de elasticidade empregados na Estratégia I, a fim de garantir a consistência entre as diferentes abordagens analisadas.

Figura 11. Diâmetros mínimo e máximo dos vazios adotados na Estratégia II.



Fonte: Própria autoria.

Figura 12. Distribuição dos agregados junto aos vazios nos cenários D_50 e D_misto.



Fonte: Própria autoria.

No que se refere à fase correspondente aos vazios, sua modelagem requer um tratamento específico. De acordo com Choren et al. (2013), materiais porosos podem ser representados como compósitos bifásicos, constituídos por uma fase sólida e outra associada aos vazios, cuja rigidez pode ser considerada nula. Nesse contexto, os vazios atuam como regiões de descontinuidade no material, sem contribuir de forma significativa para a rigidez global do compósito.

Entretanto, a adoção de um módulo de elasticidade nulo para os vazios poderia gerar instabilidades numéricas no processo de solução pelo método dos elementos finitos. Nesse

contexto, visando garantir a estabilidade das simulações, atribuiu-se aos vazios um módulo de aproximadamente 0,1% do da argamassa. Além disso, considerando que, neste estudo, as partículas são elementos sobrepostos à malha da matriz de argamassa, o módulo dos vazios é definido como -99,9% do módulo da matriz. Essa estratégia numérica foi adotada com o objetivo de anular, de forma aproximada, a contribuição da rigidez nas regiões correspondentes aos vazios durante o processo de compatibilização do modelo, resultando em uma rigidez efetiva próxima de zero nessas regiões.

3 RESULTADOS E DISCUSSÃO


3.1 Modelagens sem efeito dos vazios – análise da influência da distribuição dos agregados

A fim de avaliar o efeito da dimensão e da distribuição dos agregados na modelagem do comportamento mecânico do concreto, em especial dos campos de tensão e de deformação, são apresentados, na sequência, os resultados das simulações numéricas, sem considerar os vazios. Os campos de deslocamento vertical dos diferentes casos analisados são apresentados na Figura 13, enquanto as curvas de tensão versus deformação são apresentadas na Figura 14. Em todos os cenários simulados, observa-se um gradiente de deslocamentos ao longo da altura da chapa, com valores máximos na região superior, devido à aplicação do carregamento, e mínimos próximos à base, em razão das restrições impostas (ver Figura 10).

No caso D_25, composto por agregados de menor dimensão e maior quantidade de partículas, os deslocamentos apresentaram distribuição mais homogênea, indicando uma resposta global mais uniforme do material. Com o aumento do diâmetro dos agregados, verificou-se maior heterogeneidade no campo de deslocamentos. No caso D_50, essa heterogeneidade tornou-se mais evidente, enquanto no caso D_75, as linhas de igual deslocamento apresentaram maiores distorções, principalmente em regiões com menor concentração de agregados. No caso D_100, esse comportamento foi ainda mais acentuado, com extensas regiões contínuas de matriz exibindo maiores deslocamentos verticais.

O caso D_misto apresentou comportamento intermediário, com distribuição mais equilibrada dos deslocamentos ao longo do domínio. A presença de partículas de diferentes dimensões favoreceu uma redistribuição mais uniforme das deformações e reduziu a formação de grandes regiões contínuas de matriz. Esses resultados indicam que a combinação de diferentes classes granulométricas proporciona uma resposta mecânica mais representativa do concreto convencional.

Figura 13. Campos de deslocamento vertical dos elementos simulados.




Fonte: Própria autoria.

Com a aplicação da simulação numérica de compressão uniaxial, foram obtidos os campos de deslocamentos nodais, a partir dos quais foram determinadas as deformações correspondentes. Em seguida, foi calculado o módulo de elasticidade em cada um dos nove pontos de análise, padronizados na face superior do elemento simulado, conforme ilustrado na Figura 13.


Os valores dos módulos, considerando os deslocamentos e as tensões mensurados em cada ponto, são apresentados na Figura 15. Os resultados mostraram que o caso D_25 apresentou comportamento praticamente constante ao longo dos pontos avaliados, com valores entre 30,2 e 31,7 GPa. No caso D_50, os valores variaram de 28,4 a 30,5 GPa. No caso D_75, os valores oscilaram entre aproximadamente 28,0 e 30,2 GPa, enquanto o caso D_100 apresentou a maior heterogeneidade entre os modelos analisados, com valores entre aproximadamente 26,5 e 30,3 GPa. O caso D_misto apresentou comportamento semelhante ao do D_25, com valores entre 29,7 e 31,4 GPa.

Figura 14. Curvas tensão versus deformação.



Fonte: Própria autoria.

Figura 15. Comparação do módulo de elasticidade nos 9 pontos de análise.



Fonte: Própria autoria.

Com base nos valores obtidos nos nove pontos de análise de cada configuração granulométrica, foi determinado o módulo de elasticidade médio equivalente (Tabela 5), calculado como a média aritmética dos módulos obtidos em cada ponto, de modo a representar o comportamento global da amostra para cada distribuição de agregados. Observou-se que o caso D_25 apresentou o maior módulo de elasticidade equivalente (31,01 GPa), enquanto o caso D_100 apresentou o menor valor médio (28,67 GPa). Verificou-se ainda uma tendência de redução do módulo equivalente com o aumento do diâmetro máximo dos agregados, comportamento associado ao aumento da heterogeneidade decorrente de agregados de maior dimensão.

Tabela 5. Módulo de elasticidade equivalente obtido para os diferentes casos analisados.

Caso	Distribuição dos agregados	E médio [GPa]
D_25	Agregados de menor diâmetro	31,01
D_50	Agregados de diâmetro intermediário	29,60
D_75	Agregados de maior diâmetro	28,94
D_100	Agregados de maior diâmetro máximo	28,67
D_misto	Distribuição granulométrica mista	30,91

Fonte: Própria autoria.

As curvas tensão–deformação, em conjunto com os valores médios do módulo de elasticidade, evidenciam a influência da granulometria dos agregados na rigidez equivalente do concreto. O caso D_25 apresentou a maior inclinação da curva, indicando o maior módulo de elasticidade entre os modelos analisados. Esse comportamento está associado à distribuição mais homogênea dos agregados, que favorece uma transferência mais uniforme de tensões e reduz a concentração localizada de deformações na matriz.

O caso D_misto apresentou inclinação muito próxima da observada para D_25, sugerindo que a combinação de diferentes classes granulométricas contribui para uma distribuição mais eficiente das deformações e para uma resposta global mais rígida. Esse resultado reforça a importância da diversidade granulométrica na composição do concreto, pois reduz a formação de regiões extensas de matriz e melhora a interação entre as fases constituintes.

O caso D_50 apresentou comportamento intermediário, enquanto os casos D_75 e D_100 exibiram as menores inclinações e, conseqüentemente, os menores módulos de elasticidade. À medida que o tamanho dos agregados aumenta, a resposta mecânica torna-se mais heterogênea, com maiores variações nos campos de deslocamento e de deformação. No caso D_100, esse efeito é mais pronunciado devido à presença de extensas regiões contínuas de matriz entre os agregados, que apresentam menor rigidez e contribuem para a redução da rigidez global do compósito.

A comparação com o módulo de elasticidade experimental médio ($E = 27,4$ GPa), representado pela linha tracejada (Figura 15), mostra que todos os modelos numéricos apresentaram inclinações superiores às observadas experimentalmente, o que indica uma superestimação da rigidez do material. Esse resultado sugere que, embora a modelagem mesoestrutural seja capaz de capturar adequadamente a influência da distribuição granulométrica, ela ainda não reproduz integralmente os mecanismos responsáveis pela redução de rigidez observada no concreto real. Essa discrepância pode ser atribuída às simplificações adotadas no modelo, incluindo a representação idealizada dos agregados, a consideração de propriedades homogêneas para cada fase do material e a ausência explícita de vazios, microfissuras e outras imperfeições inerentes ao concreto. Tais características atuam como regiões de menor rigidez e favorecem a concentração de deformações, reduzindo o módulo de elasticidade efetivo do material em escala macroscópica.

3.2 Modelagem com estratégia I – penalização do módulo da argamassa


Com base nos resultados da simulação inicial, foram selecionados, para as análises subsequentes, os modelos D_50 e D_misto, por apresentarem o melhor equilíbrio entre representatividade mecânica, estabilidade dos resultados e custo computacional. O modelo D_25, embora tenha apresentado maior rigidez equivalente, demandou uma malha significativamente mais refinada devido ao elevado número de agregados, o que aumentou substancialmente o custo computacional. Por sua vez, os modelos D_75 e D_100 foram descartados por apresentarem maior heterogeneidade dos campos mecânicos e maior dispersão dos resultados, o que reduz sua representatividade nas análises comparativas desenvolvidas nesta etapa. O modelo D_50 foi escolhido por fornecer uma resposta mecânica mais homogênea e consistente, associada a um menor custo computacional, enquanto o modelo D_misto foi mantido por reproduzir de forma mais realista a distribuição granulométrica do concreto convencional, incorporando agregados de diferentes dimensões sem aumento significativo do esforço computacional.

Dessa forma, a adoção desses dois cenários permitiu analisar, de forma complementar, um modelo com resposta mecânica mais homogênea e outro com maior representatividade da mesoestrutura do concreto, incorporando, ainda, a influência dos vazios na matriz. A Figura 16 apresenta os campos de deslocamentos verticais obtidos para os modelos D_50 e D_misto, considerando a redução do módulo de elasticidade da matriz de argamassa como estratégia para representar o efeito da porosidade. Na Figura 17, apresenta-se a comparação dos valores do módulo de elasticidade dos nove pontos de análise para os modelos D_50 e D_misto, com as

médias indicadas na Tabela 6.


Os resultados mostram que a penalização aplicada à matriz de argamassa reduziu a rigidez equivalente do compósito, aproximando os valores numéricos dos resultados experimentais. O modelo D_50 apresentou módulo de elasticidade médio de 29,90 GPa, valor mais próximo do resultado experimental de 27,40 GPa, com boa concordância na maioria dos pontos analisados, apesar da subestimação observada no ponto 9. Em contraste, o modelo D_misto apresentou valores superiores em todos os pontos, mantendo a tendência de superestimação da rigidez, com diferença média de 8,75%.

Figura 16. Campos de deslocamento vertical dos elementos simulados com a Estratégia I.



Fonte: Própria autoria.

Figura 17. Comparação do módulo de elasticidade entre os cenários D_50 e D_misto com Estratégia I.



Fonte: Própria autoria.

A incorporação indireta do índice de vazios resultou em reduções do módulo de elasticidade de aproximadamente 5,74% no modelo D_50 e de 3,59% no modelo D_misto, evidenciando a influência da porosidade na resposta mecânica do material. Em relação ao valor experimental, o modelo D_50 apresentou diferença de apenas 1,82%, enquanto o modelo D_misto apresentou diferença de 8,39%, indicando maior representatividade do primeiro para a estimativa da rigidez equivalente do concreto.

Tabela 6. Comparação dos módulos de elasticidade usando a Estratégia I e sem considerar os vazios.

Cenário	Módulo médio sem considerar vazios [GPa]	Módulo médio com Estratégia I [GPa]	Diferença entre as simulações [%]
D_50	29,60	27,90	5,74
D_misto	30,91	29,8	3,59

Fonte: Própria autoria.


Embora a penalização das propriedades mecânicas tenha melhorado a concordância entre os resultados numéricos e experimentais, essa abordagem ainda constitui uma simplificação, pois os vazios não são representados explicitamente na geometria do modelo. Como perspectiva de aprimoramento, destaca-se a incorporação explícita dos vazios na malha de elementos finitos, o que permite uma representação mais realista da distribuição de tensões e deformações na mesoestrutura do concreto.

É importante destacar que a geração da malha mesoestrutural ocorre aleatoriamente, o que faz com que os agregados assumam posições distintas a cada simulação. Como consequência, cada execução do modelo gera uma configuração interna distinta da mesoestrutura do concreto.

De acordo com Wang et al. (2015a), a resposta mecânica de modelos em mesoescala é influenciada pela distribuição aleatória dos constituintes do material. Da mesma forma, Eliáš e Vořechovský (2020) demonstram que a disposição espacial dos agregados afeta as dimensões e as orientações das interfaces entre as fases, alterando os mecanismos de transferência de tensões. Além disso, Luo et al. (2021) destacam que a natureza heterogênea do concreto introduz variações locais de rigidez ao longo do domínio analisado. Assim, diferentes distribuições dos agregados podem resultar em variações locais nos valores do módulo de elasticidade nos pontos de análise, embora se espere que o módulo de elasticidade médio global permaneça relativamente estável.

Com o objetivo de avaliar a influência dessa variabilidade geométrica nos resultados numéricos, foram realizadas cinco simulações independentes, mantendo-se inalteradas as propriedades mecânicas e as condições de contorno e modificando-se apenas a distribuição espacial dos agregados na matriz. Uma dessas simulações corresponde ao modelo D_50 anteriormente apresentado na Figura 16, enquanto as demais configurações são apresentadas na Figura 18.

Figura 18. Campos de deslocamento vertical dos elementos usando D_50 em diferentes disposições.




Fonte: Própria autoria.

Observa-se que, apesar das diferenças de posicionamento dos agregados em cada modelo, os campos de deslocamento permaneceram bastante semelhantes entre si, indicando um comportamento global consistente da estrutura analisada. Pequenas heterogeneidades locais puderam ser observadas, especialmente nas regiões próximas aos agregados, devido à natureza heterogênea do concreto e à distribuição espacial dos constituintes.

Com o objetivo de avaliar quantitativamente a influência dessas variações locais, foram analisados os módulos de elasticidade obtidos nos nove pontos de análise para os cinco modelos considerados. Posteriormente, os resultados foram avaliados por meio de diagramas do tipo box plot, apresentados na Figura 19.

Os resultados mostram que o módulo de elasticidade médio variou de 27,20 GPa (P9) a 28,41 GPa (P6), evidenciando a influência da distribuição espacial dos agregados sobre a resposta mecânica local do material. Os pontos P4 e P6 apresentaram as menores amplitudes de variação entre as simulações, indicando menor sensibilidade às alterações da mesoestrutura. Por outro lado, o ponto P5 registrou a maior dispersão dos resultados, com amplitude de aproximadamente 1,78 GPa e valor máximo próximo de 29,06 GPa, o que indica maior dependência da configuração local dos agregados.

Figura 19. Variabilidade do módulo de elasticidade em função de diferentes distribuições do D_50.



Fonte: Própria autoria.

Apesar dessas variações pontuais, os valores médios permaneceram concentrados em torno de 27 GPa na maioria dos pontos analisados, sendo o ponto P6 a única exceção, com média próxima de 28 GPa. De modo geral, a reduzida variação entre os resultados médios globais indica que a aleatoriedade na distribuição dos agregados afeta principalmente a resposta local do material, sem comprometer a estimativa do módulo de elasticidade global. Esses resultados evidenciam a boa estabilidade numérica e a consistência estatística da modelagem adotada, conforme apresentado na Tabela 7.

Tabela 7. Módulo de elasticidade médio e parâmetros estatísticos associados aos elementos com D_50.

Distribuição dos agregados	Módulo de Elasticidade [GPa]	Desvio Padrão [GPa]	Coefficiente de Variação [%]
D_50	27.9	0.10	0.36
D_50_II	27.7		
D_50_III	27.8		
D_50_IV	27.9		
D_50_V	27.7		


Fonte: Própria autoria.

Os resultados médios do módulo de elasticidade apresentaram baixa dispersão entre as diferentes simulações. O desvio padrão foi de aproximadamente 0,10 GPa, indicando proximidade entre os resultados, mesmo com diferentes configurações espaciais dos agregados. Além disso, o coeficiente de variação foi de aproximadamente 0,36%, valor considerado baixo para análises numéricas de materiais heterogêneos, como o concreto (Ostoja-Starzewski, 2006). Esses resultados demonstram que a alteração do posicionamento dos agregados produziu apenas pequenas variações no módulo médio de elasticidade, indicando que o comportamento global do modelo permaneceu praticamente inalterado entre as diferentes simulações realizadas e que a malha dos agregados não apresenta interferência significativa nos resultados da simulação em mesoescala do presente estudo.

3.3 Modelagem com estratégia II – poros representados por elementos finitos

Na Figura 20 apresentam-se os resultados dos deslocamentos verticais obtidos para os casos D_50 e D_misto, considerando a incorporação explícita dos vazios na mesoestrutura.

Figura 20. Análises dos deslocamentos verticais dos cenários D_50 e D_misto usando a Estratégia II.




Fonte: Própria autoria.

A incorporação explícita dos vazios alterou significativamente os campos de deslocamentos obtidos, evidenciando o papel dessas discontinuidades na redistribuição das deformações da matriz de argamassa. Em comparação com as estratégias anteriores, observa-se um aumento da heterogeneidade dos deslocamentos, associado à redução localizada da rigidez decorrente da presença de vazios. Essas regiões atuam como zonas de concentração de deformações, modificando os caminhos de transferência de tensões no interior do compósito.

No modelo D_50, os maiores deslocamentos concentram-se em regiões com maior densidade de vazios e menor confinamento dos agregados, o que resulta em gradientes de deformação mais pronunciados. Já no modelo D_misto, embora a influência dos vazios também seja evidente, a presença de agregados de diferentes dimensões favorece uma distribuição mais uniforme das deformações. Esse comportamento sugere que a diversidade granulométrica contribui para reduzir os efeitos localizados das discontinuidades, promovendo uma redistribuição mais eficiente das tensões na mesoestrutura.

Os resultados apresentados na Figura 21 demonstram que a representação explícita dos vazios resultou em uma redução mais significativa do módulo de elasticidade em comparação às abordagens anteriores. Para o modelo D_50, todos os pontos analisados apresentaram valores inferiores ao módulo experimental de 27,40 GPa, indicando que a presença explícita de vazios resultou em uma redução excessiva da rigidez equivalente do compósito.



O modelo D_misto apresentou comportamento distinto, com valores sistematicamente superiores aos obtidos para o D_50 e, em diversos pontos, próximos aos valores experimentais. Esse resultado indica que a distribuição granulométrica mista contribui para mitigar

parcialmente os efeitos da porosidade sobre a rigidez global do material. Entretanto, observa-se maior dispersão dos resultados entre os pontos analisados, o que evidencia que a resposta mecânica se torna mais dependente da interação local entre agregados, matriz e vazios.

A Tabela 8 apresenta a comparação entre os módulos médios de elasticidade obtidos sem considerar os vazios e aqueles determinados utilizando a Estratégia II. Observa-se que, para o cenário D_50, o módulo médio de elasticidade foi reduzido de 29,60 GPa para 25,17 GPa, enquanto, para o cenário D_misto, houve redução de 30,91 GPa para 26,26 GPa. Esses resultados correspondem a reduções de aproximadamente 15% em ambos os cenários, evidenciando que a representação explícita dos vazios influencia significativamente a rigidez equivalente do concreto. Esse comportamento era esperado, uma vez que a presença dos vazios reduz a área efetiva resistente e promove a redistribuição das tensões na matriz cimentícia, resultando em diminuição do módulo de elasticidade global do compósito.

Tabela 8. Comparação dos módulos de elasticidade usando a Estratégia II e sem considerar os vazios.


Cenário	Módulo médio sem considerar vazios [GPa]	Módulo médio com Estratégia II [GPa]	Diferença entre as simulações [%]
D_50	29,60	25,17	14,97
D_misto	30,91	26,26	15,04

Fonte: Própria autoria.

Em termos gerais, os resultados mostram que a modelagem explícita dos vazios captura, de forma mais direta, os mecanismos responsáveis pela redução da rigidez do concreto. Diferentemente da Estratégia I, em que a porosidade foi considerada apenas por meio da penalização das propriedades mecânicas da matriz, a Estratégia II incorpora os vazios como descontinuidades geométricas, resultando em alterações mais expressivas nos campos de deformação e, conseqüentemente, nos valores do módulo de elasticidade equivalente.

Na Figura 22, é apresentada uma comparação do módulo de elasticidade para os casos D_50 e D_misto, considerando as duas estratégias adotadas no estudo e o caso em que não foi incorporado o efeito da porosidade.

Figura 22. Comparação do módulo de elasticidade para cada condição de simulação.



Fonte: Própria autoria.

A comparação entre as estratégias de modelagem evidencia que o desempenho de cada abordagem depende da configuração mesoestrutural considerada. Para o modelo D_50, a Estratégia I apresentou a melhor concordância com os resultados experimentais, com diferença aproximada de 1,82%, indicando que a consideração indireta da porosidade, por meio da penalização das propriedades da matriz, foi suficiente para reproduzir adequadamente a rigidez equivalente do material.

Para o modelo D_misto, a Estratégia II apresentou a melhor aproximação ao valor experimental, com uma diferença de aproximadamente 4,16%. Esse resultado sugere que, em distribuições granulométricas mais representativas do concreto real, a modelagem explícita dos vazios contribui para uma descrição mais realista da resposta mecânica do compósito.

De forma geral, a consideração da porosidade exerce influência significativa na estimativa do módulo de elasticidade, e sua representação explícita tende a capturar com maior fidelidade os mecanismos locais de deformação. Entretanto, a estratégia baseada na penalização das propriedades mecânicas apresenta menor custo computacional e, para determinadas configurações em mesoescala, pode fornecer resultados igualmente satisfatórios. Dessa forma, a escolha da estratégia de modelagem deve considerar o equilíbrio entre a precisão na representação física do material e a eficiência computacional.

3.4 Avaliação de desempenho das estratégias em concretos com diferentes composições

A fim de avaliar se o desempenho das estratégias I e II é invariante em relação à composição do concreto, para concretos distintos do C25 utilizado nas simulações anteriores, foram

realizadas novas modelagens com concretos de diferentes relações água-cimento, proporções dos materiais secos, tipos de agregado e diâmetros máximos dos agregados. Os dados dos concretos simulados foram extraídos da literatura e considerados concretos com agregados basálticos, graníticos e de gnaiss.

Com base nos dados disponíveis, foi determinado o índice de vazios por meio de um modelo de RNAs, o que possibilitou a aplicação das estratégias de modelagem já descritas. Os traços de concreto, as características dos agregados e os índices de vazios estimados pelo modelo de RNAs são apresentados na Tabela 9.

Tabela 9. Traços, características dos agregados e índices de vazios dos concretos avaliados.


Fonte	Traço do Concreto (C:A:B)	Relação w/c	Tipo de agregado	Diâmetro máximo do agregado [mm]	Índice de vazios [%]
Félix et al. (2024)	1:2,26:2,89	0,52	Gnaiss	19	9,15
Frotté et al. (2017)	1:2,9:3,16	0,645	Granito	19	12,96
Meireles (2005)	1:1,24:2,14	0,4	Basalto	19	13,90
Almeida (2012)	1:1,4:2,0	0,45	Gnaiss	12,5	13,0

Fonte: Própria autoria.

Foram aplicadas as duas estratégias de modelagem que consideram a incorporação dos efeitos dos vazios e a configuração inicial de simulação sem esses efeitos. Para as simulações, foi selecionada apenas a representação dos agregados com o D₅₀. Essa escolha deve-se à melhor concordância com os resultados experimentais, especialmente na Estratégia I, o que demonstra maior capacidade de representar a resposta mecânica do concreto, em comparação com os resultados obtidos com o concreto C25. Além disso, o modelo D₅₀ apresentou maior simplicidade de implementação, pois o tamanho característico dos agregados é definido diretamente como 50% do diâmetro máximo, o que reduz as incertezas associadas à definição da mesoestrutura.

A partir dessas informações, foram realizadas simulações numéricas, permitindo a comparação entre os valores obtidos e os resultados experimentais, conforme apresentado na Figura 23.

Figura 23. Comparação entre os resultados experimentais e os resultados numéricos das simulações.



Fonte: Própria autoria.

Os resultados evidenciam um comportamento consistente entre as estratégias de modelagem avaliadas. De forma geral, sim a incorporação dos vazios no modelo o módulo de elasticidade é superior aos obtidos experimentalmente, o que indica uma tendência a superestimar a rigidez do concreto. Em contrapartida, a Estratégia II resultou em valores predominantemente inferiores aos valores experimentais, caracterizando uma tendência de subestimação da rigidez. Entre as abordagens analisadas, a Estratégia I apresentou os melhores resultados, com valores mais próximos dos experimentais e menores diferenças na maioria dos casos estudados. Esse comportamento indica que a consideração indireta da porosidade, por meio da penalização das propriedades mecânicas da matriz, foi capaz de representar de forma mais adequada a resposta mecânica do material.

Para quantificar a precisão de cada estratégia, foi calculado o Desvio Percentual Absoluto Médio (MAPE – Mean Absolute Percentage Error), definido pela Equação 5 (Carmo e Silva, 2023). Os MAPEs de cada estratégia são apresentados na Tabela 10.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{E_{num} - E_{exp}}{E_{exp}} \right| * 100 \quad \text{Equação 5}$$

Em que E_{num} corresponde ao módulo de elasticidade obtido numericamente, E_{exp} ao valor experimental de referência e (n) ao número de casos analisados.

Tabela 10. Desvios percentuais médios absolutos de cada estratégia.

Fonte dos dados	Módulo de elasticidade experimental [GPa]	Erro obtido com a modelagem sem o efeito dos vazios [%]	Erro obtido com a Estratégia I [%]	Erro obtido com a Estratégia II [%]
Félix et al. (2024)	35,74	4,84	1,59	11,05
Frotté et al. (2017)	33,70	6,94	1,81	15,79
Meireles (2005)	32,42	10,06	0,56	15,51
Almeida (2012)	31,41	9,55	0,16	12,57
MAPE	--	7,85	1,03	13,73

Fonte: Própria autoria.

A modelagem, sem considerar os vazios, superestimou os valores experimentais em todos os casos, com desvios absolutos variando entre 4,84% e 10,06%, resultando em um MAPE de 7,85%. A Estratégia II, por sua vez, subestimou sistematicamente os resultados de referência, registrando os maiores desvios entre as abordagens avaliadas, de 11,05% a 15,79%, e um MAPE de 13,73%. A Estratégia I destacou-se como a mais precisa, apresentando desvios absolutos inferiores a 2% em todos os casos e um MAPE de apenas 1,03%, o que demonstra que é a abordagem que melhor representa o comportamento elástico do concreto entre as estratégias investigadas.

4 CONCLUSÕES

O presente estudo investigou o comportamento mecânico do concreto em mesoescala por meio de uma abordagem integrada entre o Método dos Elementos Finitos Posicionais e técnicas de aprendizado de máquina, considerando a influência da distribuição granulométrica dos agregados e da presença de vazios sobre o módulo de elasticidade do compósito. Para isso, foram abordadas estratégias distintas de modelagem, permitindo avaliar progressivamente os efeitos da heterogeneidade da mesoestrutura sobre a resposta mecânica do material.

As simulações, sem considerar o efeito dos poros, apresentaram tendência a superestimar a rigidez do concreto. Para o concreto de referência, os módulos obtidos variaram entre 28,67 GPa e 31,01 GPa, enquanto o valor experimental médio foi de 27,40 GPa. Na validação com dados concretos extraídos da literatura, essa abordagem apresentou erros absolutos entre 4,84% e 10,06%, resultando em um MAPE de 7,85%. Embora apresente menor complexidade de modelagem e menor custo computacional, essa estratégia não considera mecanismos importantes associados à porosidade do material, o que resulta em uma representação excessivamente rígida do concreto.

Ao avaliar o efeito da dimensão e da distribuição dos agregados, verificou-se que ambos influenciam significativamente a resposta mecânica do concreto. Os módulos de elasticidade equivalentes variaram de 28,67 GPa no caso D_100 a 31,01 GPa no caso D_25, o que representa uma diferença de aproximadamente 8,2% entre os cenários extremos. Observou-se, ainda, uma tendência de redução da rigidez com o aumento do diâmetro dos agregados, associada ao aumento da heterogeneidade dos campos de deslocamento e de deformação. O caso D_misto apresentou módulo equivalente de 30,91 GPa, valor próximo ao obtido para o D_25, indicando que a combinação de diferentes classes granulométricas favorece uma distribuição mais uniforme de tensões e deformações.

A incorporação indireta da porosidade, por meio da penalização das propriedades mecânicas da argamassa (Estratégia I), reduziu a rigidez equivalente e melhorou a concordância com os resultados experimentais. Para o modelo D_50, a penalização reduziu o módulo de elasticidade de 29,60 GPa para 27,90 GPa, o que corresponde a uma redução de 5,74%. No modelo D_misto, a redução foi de 30,91 GPa para 29,80 GPa, o que corresponde a 3,59%. Em relação ao valor experimental de 27,40 GPa, o modelo D_50 apresentou erro de apenas 1,82%, enquanto o D_misto apresentou erro de 8,39%. Na avaliação com concretos de diferentes composições, essa estratégia apresentou os menores erros entre todas as abordagens avaliadas, com desvios inferiores a 2% em todos os casos e um MAPE de 1,03%.

Os resultados demonstram que a Estratégia I apresentou o melhor desempenho global entre as metodologias investigadas. Além da maior precisão, a abordagem apresenta vantagens relevantes do ponto de vista computacional, pois não exige refinamento adicional da malha nem a representação geométrica explícita dos vazios. Sua principal limitação está associada ao fato de representar a porosidade de forma homogeneizada, sem capturar diretamente os efeitos locais da distribuição espacial dos vazios nos campos de tensão e deformação, o que pode comprometer análises não lineares, nas quais o efeito da plastificação e da fissuração é importante.

A modelagem explícita dos vazios (Estratégia II) permitiu reproduzir de forma mais realista a heterogeneidade interna do concreto e os mecanismos locais associados à concentração de deformações. Os resultados mostraram um aumento da heterogeneidade dos campos de deslocamento e uma maior sensibilidade da resposta mecânica à distribuição espacial dos vazios. Entretanto, essa estratégia resultou em uma redução excessiva da rigidez equivalente do material. Para o caso D_50, todos os valores obtidos ficaram abaixo do módulo experimental de referência, enquanto, para o caso D_misto, observou-se uma melhor aproximação aos resultados experimentais. Na avaliação com dados concretos da literatura com diferentes

composições, essa abordagem apresentou erros entre 11,05% e 15,79%, resultando em MAPE de 13,73%, o maior entre as metodologias avaliadas.

Embora tenha apresentado menor precisão global na estimativa do módulo de elasticidade, a modelagem explícita dos vazios tem a vantagem de representar diretamente a influência geométrica das descontinuidades na mesoestrutura, permitindo análises mais detalhadas dos mecanismos locais de deformação. Dessa forma, essa abordagem mostra-se particularmente promissora para estudos que envolvem a concentração de tensões, a propagação de fissuras, o dano e o comportamento não lineares do concreto.

A análise da influência da distribuição aleatória dos agregados demonstrou que a variabilidade geométrica afeta predominantemente a resposta local do material. As cinco simulações independentes realizadas para o modelo D_50 apresentaram módulo de elasticidade médio de aproximadamente 27,8 GPa, desvio padrão de apenas 0,10 GPa e coeficiente de variação de 0,36%. Esses resultados indicam a estabilidade numérica e demonstram que o procedimento de geração aleatória da mesoestrutura não compromete a estimativa das propriedades mecânicas globais do material.

De modo geral, conclui-se que a porosidade é um dos principais fatores responsáveis pela discrepância entre modelos mesoestruturais idealizados e resultados experimentais. Entre as estratégias avaliadas, a incorporação indireta dos vazios, por meio da penalização das propriedades da matriz, mostrou-se a abordagem mais adequada para a estimativa do módulo de elasticidade do concreto em mesoescala, conciliando representatividade física, robustez numérica e eficiência computacional.

REFERENCIAS

AHMED, Hassan; KUVA, Jukka.; PUNKKI, Jouni. Analysing entrapped pores in concrete via X-ray computed tomography: influence of workability and compaction time. *Construction and Building Materials*, v. 417, art. 135322, 2024. DOI: 10.1016/j.conbuildmat.2024.135322.

ALMEIDA, Silvio. Análise do módulo de elasticidade estático e dinâmico do concreto de cimento Portland através de ensaios de compressão simples e de frequência ressonante. 2012. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2012.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 9778: Argamassa e concreto endurecidos – Determinação da absorção de água, índice de vazios e massa específica. Rio de Janeiro: ABNT, 2005.

AZEVEDO, Álvaro. Método dos elementos finitos. Porto: Faculdade de Engenharia da Universidade do Porto, 2003.

BADUGE, Shanaka Kristombu; MENDIS, Priyan; THILAKARATHNA, Sadeep; VIMONSATIT, Vanissorn. Multiscale modeling of concrete. Cambridge: Woodhead Publishing, 2025.

BARRETO, Jairo Orlando Fuentes; FÉLIX, Emerson Felipe. Aplicação de redes neurais artificiais para a predição do índice de vazios de concretos com e sem agregados de RCD. IBRACON. 2025.

BORGES, Danilo; QUARESMA, Wanessa; FERNANDES, Gabrielar; PITUBA, Júlio. Evaluation of a proposed model for concrete at mesoscopic scale. *Revista IBRACON de Estruturas e Materiais*, v. 10, n. 5, p. 1087–1112, set. 2017.

CHOREN, Julie; HEINRICH, Scott; SILVER-THORN, Blair. Young's modulus and volume porosity relationships for additive manufacturing applications. *Journal of Materials Science*, v. 48, n. 15, p. 5103–5112, 2013. DOI: 10.1007/s10853-013-7237-5.

CODA, Humberto Breves; GRECO, Marcelo. A simple FEM formulation for large deflection 2D frame analysis based on position description. *Computer Methods in Applied Mechanics and Engineering*, v. 193, n. 33–35, p. 3541–3557, 2004. DOI: 10.1016/j.cma.2004.01.023.

CODA, Humberto Breves; PACCOLA. A positional FEM formulation for geometrical non-linear analysis of shells. In: CONGRESSO NACIONAL DE MECÂNICA COMPUTACIONAL (CILAMCE), 29., 2008. *Anais...* Maceió: ABMEC, 2008

CODA, Humberto Breves; PACCOLA. Unconstrained finite element for geometrical nonlinear dynamics of shells. *Mathematical Problems in Engineering*, v. 2009, Article ID 575131, 2009. DOI: 10.1155/2009/575131.

CODA, Humberto Breves; PACCOLA. A FEM procedure based on positions and unconstrained vectors applied to non-linear dynamic of 3D frames. *Finite Elements in Analysis and Design*, v. 47, n. 4, p. 319–333, 2011. DOI: 10.1016/j.finel.2010.11.001.

FARIAS; RIBEIRO; SOUZA. Avaliação da influência do agregado graúdo de diferentes composições mineralógicas no módulo de elasticidade do concreto. 2018.

FEI, Zhengyu; LIANG, Shixue; CAI, Yiqing; SHEN, Yuanxie. Ensemble machine-learning-based prediction models for the compressive strength of recycled powder mortar. *Materials*, v. 16, n. 2, art. 583, 2023. DOI: 10.3390/ma16020583.

FÉLIX, Emerson Felipe. Modelagem da deformação do concreto armado devido à formação dos produtos de corrosão. 2018. Dissertação (Mestrado) – Universidade de São Paulo, São Carlos, 2018.

FÉLIX, Emerson Felipe. Estudo numérico-experimental da fadiga em concretos submetidos à compressão cíclica: proposição de um modelo de dano acumulado. 2022. Tese (Doutorado) – Universidade de São Paulo, São Carlos, 2022.

FÉLIX, Emerson Felipe; FALCÃO, Isabela; SANTOS, Gabriela; PRADO, Lisiane. A three-phase approach to modeling the mechanical behavior of concrete and predicting the elastic modulus. In: CONGRESSO LUSO-BRASILEIRO DE MATERIAIS DE CONSTRUÇÃO SUSTENTÁVEIS, 2024. *Anais*. 2024.

FORTI, Tiago; BATISTELA, Gustavo; FORTI, Nadia; VIANNA, Nicolas. 3D mesoscale finite element modelling of concrete under uniaxial loadings. *Materials*, v. 13, n. 20, art. 4585, 2020. DOI: 10.3390/ma13204585.

FROTTE, Camila; DI NUBILA, Clarisse Sophia Alejandra; NAGALLI, André; MAZER, Wellington; MACIOSKI, Gustavo; OLIVEIRA, Luna Ollin Steffen de. Estudo das propriedades físicas e mecânicas de concreto com substituição parcial de agregado natural por agregado reciclado proveniente de RCD. *Revista Matéria*, v. 22, n. 2, e11871, 2017. DOI: 10.1590/S1517-707620170002.0143.

LI, Yi.; SHENG, Junlei; LI, Wei.; YU, Mengxuan.; ZHENG, Xiaotian.; WANG, Fuzhou. Effect of a novel spherical tailings aggregate on the macro- and mesoscopic properties of pervious concrete. *Cement and Concrete Composites*, v. 144, art. 105311, 2023. DOI: 10.1016/j.cemconcomp.2023.105311.

LYU, Kai; GARBOCZI; LIU, Xiaoyan. A quantitative characterization of spatial arrangement of air voids in mortars via X-ray CT and numerical calculations. *Construction and Building Materials*, v. 360, art. 129550, 2022. DOI: 10.1016/j.conbuildmat.2022.129550.

MAZONI, Ivan; TABORDA, Andreia. Comparação de materiais na engenharia civil: desempenho e sustentabilidade de estruturas de concreto, metal e madeira. *Caderno Progressus*, 2024.

MEIRELES, Priscila. Análise da influência da massa específica de agregados graúdos provenientes de resíduos de construção e demolição no desempenho mecânico do concreto. 2005. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

MOURA, Camila. Aplicação de formulação baseada no Método dos Elementos Finitos Posicional na análise bidimensional elástica de compósitos particulados. 2015. Dissertação (Mestrado) – Universidade de São Paulo, São Carlos, 2015.

MURSHIDA; JIYAD; NAGARAJAN, Praveen. Development of mesoscopic model for concrete – A critical review. *Materials Today: Proceedings*, 2023.

NETO, Pompoe; OLIVEIRA, Denio; RAMOS, Danielli Efeitos do tipo, tamanho e teor de agregado graúdo no módulo de deformação do concreto de alta resistência. *Revista Matéria*, 2023.

PACCOLA; CODA, Humberto Breves. A direct FEM approach for particulate reinforce elastic solids. *Composite Structures*, v. 141, p. 282–291, 2016. DOI: 10.1016/j.compstruct.2016.01.062.

PRAYOGO, D.; SANTOSO, D. I.; WIJAYA, D.; GUNAWAN, T.; WIDJAJA, J. A. Prediction of concrete properties using ensemble machine learning methods. *Journal of Physics: Conference Series*, v. 1625, n. 1, art. 012024, 2020. DOI: 10.1088/1742-6596/1625/1/012024.

RAMOS, Everton.; CARRAZEDO, Rogerio; PACCOLA, Rodrigo. Modeling particles elements in damaged reinforced concrete structures. *Latin American Journal of Solids and Structures*, v. 18, n. 1, p. 1–24, 2021. DOI: 10.1590/1679-78256251.

RODRIGUES, Eduardo; MANZOLI, Osvaldo; BITENCOURT, Luis.; BITTENCOURT, Tulio. 2D mesoscale model for concrete based on the use of interface element with a high aspect ratio. *International Journal of Solids and Structures*, v. 94–95, p. 112–124, 2016. DOI: 10.1016/j.ijsolstr.2016.05.004.

RODRÍGUEZ-BRITO, Natalia; BLANCO-PENALVER, Concepcion; SOUTO, Ricardo; ANDRADE, Carmen; SANTANA, Juan. Reassessment of porosimetry determinations using water vapor sorption measurements for pastes and concretes containing basaltic aggregates compared to the mercury intrusion method. *Materials*, v. 18, n. 10, art. 2257, 2025. DOI: 10.3390/ma18102257.

SANTOS, Larissa Gabriela dos; FALCÃO, Isabela da Silva; FÉLIX, Emerson Felipe; PRADO, Lisiane Pereira. Predição do índice de vazios de concretos com RCD: proposição de modelo baseado em aprendizado de máquina e validação experimental. In: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2024. Anais [...]. 2024.

SPRIGGS. Expression for effect of porosity on elastic modulus of polycrystalline refractory materials, particularly aluminum oxide. *Journal of the American Ceramic Society*, v. 44, n. 12, p. 628–629, 1961. DOI: 10.1111/j.1151-2916.1961.tb11671.x.

THILAKARATHNA, Petikirige Sadeep Madhu Shan; BADUGE, Kasun Shanaka Kristombu; MENDIS, Priyan; VIMONSATIT, Vanissorn; LEE, Hyuk. Mesoscale modelling of concrete – A review of geometry generation, placing algorithms, constitutive relations and applications. *Engineering Fracture Mechanics*, Elsevier Ltd, 15 maio 2020.

VASCONCELLOS, Alex. Estudo da variabilidade do módulo de elasticidade de concretos produzidos com diferentes tipos de agregados graúdos. 2018. Dissertação (Mestrado em Engenharia Civil) – Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2018.

VIEIRA, Welington. Sobre o estudo de modelos numéricos aplicados à simulação multiescala do comportamento de estruturas de concreto. 2021. Dissertação (Mestrado em Engenharia de Estruturas) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2021.

VIEIRA, Welington; CODA, Humberto Breves; PACCOLA, Rodrigo. A direct FEM approach to model mesoscale concrete and connect non-matching meshes in multiscale analysis. *Revista IBRACON de Estruturas e Materiais*, v. 17, n. 1, 2024. DOI: 10.1590/S1983-41952024000100011.

VIEIRA, Welington; PACCOLA, Rodrigo; CODA, Humberto Breves. Crack analysis of mesoscale concrete by FEM using an alternative mesh overlay to represent mortar and coarse aggregate. 2021.

WANG, Xiaofei; YANG, Zhi Jian; YATES, John R.; JIVKOV, Andrey P.; ZHANG, Chunsheng. Monte Carlo simulations of mesoscale fracture modelling of concrete with random aggregates and pores. *Construction and Building Materials*, v. 75, p. 35–45, 2015.

WEI, Shuaishuai; ZHANG, Huan; WANG, Ding.; WANG, Xuchun.; CAO, Mengdi. Mesoscale mechanical analysis of concrete based on a 3D random aggregate model. *Coatings*, v. 15, n. 8, art. 883, 2025. DOI: 10.3390/coatings15080883.

WILSON; CARTER; HOFF. British Standard and RILEM water absorption tests: a critical evaluation. *Materials and Structures*, v. 32, n. 8, p. 571–578, 1999.

XU, Chenyang; LI, Qiuyi; WANG, Peihan; FAN, Qianqian; KONG, Zhe; WANG, Lliang; YUE, Gongbing; ZHENG, Shidong; SHAO, Changhai; GUO, Yuanxin. Theoretical porosity design, mechanical properties, and durability of large-pore sandy recycled concrete. *Case Studies in Construction Materials*, v. 21, art. e03655, 2024. DOI: 10.1016/j.cscm.2024.e03655.

YANG, Lifu; YIN, Hao; SU, Huaizhi; YAO, Kefu.; ALNAGGAR, Mohammed; DI LUZIO, Giovanni.; CUSATIS, Gianluca. A multiscale homogenization approach for multiphysics lattice modeling of alkali-silica reaction in concrete: upscaling coupled mechanics and mass transport. *Cement and Concrete Research*, v. 205, art. 108230, 2026. DOI: 10.1016/j.cemconres.2026.108230.

ZHANG, Longfei; XIE, Hao; FENG, Jili. Mesoscale modeling and failure mechanism of concrete considering pore structures and actual aggregate shapes. *Construction and Building Materials*, v. 353, 24 out. 2022.

ZHU, Chunquin; ZHU, Eryu; WANG, Bin; LI, Jiacheng; YAO, Tong; ZHANG, Zhu. Effect of porosity and pore size on the axial compressive properties of recycled aggregate concrete. *Materials*, v. 18, n. 12, art. 2830, 2025. DOI: 10.3390/ma18122830.

4 CONCLUSÕES

4.1 CONSIDERAÇÕES FINAIS

Este trabalho avaliou abordagens integradas entre Redes Neurais Artificiais (RNAs) e o Método dos Elementos Finitos Posicionais (MEFP) para incorporar os efeitos da porosidade na modelagem em mesoescala do concreto e avaliar sua influência sobre o módulo de elasticidade do material. A pesquisa foi estruturada em duas etapas complementares: a primeira, dedicada ao desenvolvimento de um modelo preditivo do índice de vazios por meio de aprendizado de máquina, e a segunda, voltada à incorporação dessa informação à simulação em mesoescala.

Na primeira etapa, os resultados demonstraram a viabilidade do uso de RNAs para prever o índice de vazios em concretos produzidos com diferentes composições e tipos de agregados. Os modelos desenvolvidos foram capazes de capturar as relações não lineares entre as variáveis de entrada e a porosidade do material. A arquitetura com duas camadas ocultas apresentou desempenho superior à rede com uma única camada oculta, elevando a média do coeficiente de determinação de 0,81 para 0,87. Entre as topologias avaliadas, a configuração [6-7-5-1] apresentou o melhor desempenho, alcançando coeficiente de determinação de 0,89 e uma distribuição mais uniforme dos resíduos.

A comparação com o modelo analítico de Neville e Brooks (1998) evidenciou a superioridade da abordagem baseada em aprendizado de máquina no conjunto de dados analisado. Enquanto a RNA apresentou erro absoluto médio (MAE) de 0,009, o modelo analítico apresentou MAE de 0,048, o que representa um erro aproximadamente 5 vezes maior.

A análise de importância das variáveis demonstrou que o tipo de cimento foi o parâmetro de maior influência na previsão do índice de vazios, independentemente da arquitetura utilizada no treinamento, considerando o banco de dados empregado. Esse resultado pode indicar o papel do ligante na formação da microestrutura do concreto, demonstrando que a porosidade não depende exclusivamente da relação água/cimento ou da quantidade de agregados, mas também da interação entre múltiplos fatores relacionados à composição do material.

Na segunda etapa do trabalho, a porosidade estimada pelas RNAs foi incorporada às simulações desenvolvidas com o MEFP. Inicialmente, verificou-se que

a desconsideração dos vazios resulta em superestimação da rigidez do concreto. Os modelos que não consideraram a porosidade apresentaram módulos de elasticidade entre 28,67 GPa e 31,01 GPa, enquanto o valor experimental médio foi de 27,40 GPa. Na validação com concretos obtidos da literatura, essa abordagem apresentou erros entre 4,84% e 10,06%, resultando em um MAPE de 7,85%.

A análise da influência da dimensão e da distribuição dos elementos particulados utilizados na representação dos agregados graúdos afeta significativamente a resposta mecânica do material. Observou-se redução do módulo de elasticidade à medida que aumentava o diâmetro dos agregados, com diferença de aproximadamente 8,2% entre os casos extremos D_25 e D_100. Além disso, agregados maiores produziram campos de deslocamento e deformação mais heterogêneos, enquanto distribuições granulométricas mais refinadas ou mistas favoreceram uma resposta mecânica mais uniforme.

A incorporação indireta da porosidade, por meio da penalização das propriedades mecânicas da matriz (Estratégia I), apresentou o melhor desempenho entre as abordagens avaliadas. Para o modelo D_50, observou-se uma redução de 5,74% no módulo de elasticidade, enquanto, para o modelo D_misto, a redução foi de 3,59%. Em relação ao valor experimental de 27,40 GPa, o modelo D_50 apresentou um erro de apenas 1,82%. Na modelagem com concretos de diferentes composições, essa estratégia apresentou desvios inferiores a 2% em todos os casos avaliados e um MAPE de 1,03%, o que demonstra boa capacidade preditiva.

Além da precisão alcançada, a Estratégia I apresentou importantes vantagens computacionais. A metodologia não requer refinamento adicional da malha, não aumenta significativamente o custo computacional e pode ser aplicada diretamente a diferentes concretos com base no índice de vazios estimado pela RNA. Dessa forma, a abordagem mostrou-se adequada para aplicações em que o principal interesse recai sobre a estimativa de propriedades globais do material, como o módulo de elasticidade.

A modelagem explícita dos vazios (Estratégia II), por meio da representação dos vazios por elementos finitos, permitiu representar de forma mais realista a heterogeneidade interna do concreto. Os resultados evidenciaram um aumento da heterogeneidade da resposta mecânica e maior sensibilidade à distribuição espacial dos vazios. Entretanto, essa abordagem apresentou tendência à subestimação da rigidez do material, resultando em erros entre 11,05% e 15,79% e em um MAPE de

13,73%.

Apesar da menor precisão na estimativa do módulo de elasticidade, a Estratégia II apresenta vantagens importantes do ponto de vista físico, uma vez que representa explicitamente as descontinuidades geométricas da mesoestrutura. Essa característica auxilia na representação de mecanismos locais de concentração de tensões e deformações que não são reproduzidos pela abordagem homogeneizada da Estratégia I. Consequentemente, sua aplicação pode ser relevante em estudos envolvendo fissuração, dano, propagação de trincas e comportamento não linear do concreto.

A análise da variabilidade associada ao posicionamento aleatório dos agregados demonstrou que a geração estocástica da mesoestrutura influencia predominantemente os resultados locais, mas não os globais. As cinco simulações independentes realizadas para o modelo D_50 apresentaram módulo de elasticidade global médio de aproximadamente 27,8 GPa, desvio padrão de apenas 0,10 GPa e coeficiente de variação de 0,36%, evidenciando a robustez e a estabilidade numérica da metodologia proposta.

Como principal contribuição, este trabalho demonstrou que a integração entre Redes Neurais Artificiais e o Método dos Elementos Finitos, na versão Posicional, constitui uma estratégia eficiente para incorporar os efeitos da porosidade em simulações em mesoescala. A utilização de RNAs para estimar parâmetros físico-mecânicos do concreto, permite transformar uma variável de difícil obtenção experimental em um parâmetro diretamente utilizável em simulações numéricas, reduzindo a dependência de ensaios específicos e ampliando a aplicabilidade dos modelos desenvolvidos.

4.2 LIMITAÇÕES DO ESTUDO

Entre as limitações do estudo, destaca-se que o modelo de RNA foi desenvolvido a partir de uma base de dados compilada da literatura, o que o torna sujeito às variabilidades inerentes aos diferentes materiais, procedimentos experimentais e condições de ensaio empregados pelos autores originais. Além disso, fatores potencialmente relevantes para a porosidade do concreto, como o uso de aditivos químicos, diferentes condições de cura e características mais detalhadas dos agregados, não foram considerados nas variáveis de entrada. Outra limitação refere-

se ao domínio de aplicação dos RNAs, que deve permanecer restrito aos intervalos de treinamento utilizados no desenvolvimento do modelo.

No âmbito da modelagem numérica, a Estratégia I considera a porosidade de forma homogeneizada, sem representar explicitamente os mecanismos locais associados à distribuição espacial dos vazios. Já a Estratégia II, embora fisicamente mais representativa, ainda emprega uma idealização bidimensional da mesoestrutura e não contempla mecanismos não lineares relacionados à fissuração, à plastificação ou à evolução do dano.

4.3 SUGESTÕES PARA TRABALHOS FUTUROS

Para a melhoria e desenvolvimento da área de estudo do presente trabalho, recomenda-se a ampliação da base de dados utilizada no treinamento das RNAs, incorporando novas variáveis relacionadas à composição, ao processo de produção e às condições de cura do concreto. Também se sugere investigar arquiteturas mais avançadas de aprendizado de máquina e utilizar técnicas de interpretabilidade para aprofundar a compreensão dos mecanismos que regem a formação da porosidade. Junto à modelagem, recomenda-se a condução de mais estudos experimentais para avaliar a porosidade em concretos com diferentes adições minerais e tipos de cimento.

No campo da modelagem em mesoescala, recomenda-se a extensão da metodologia para análises tridimensionais, a incorporação explícita da zona de transição interfacial entre agregado e argamassa, a consideração de modelos constitutivos não lineares e a avaliação da influência da porosidade nos fenômenos de dano e na propagação de fissuras.

5 REFERÊNCIAS

- AHMAD, Shamsad.; AZAD, Abul Kalam. An exploratory study on correlating the permeability of concrete with its porosity and tortuosity. *Advances in Cement Research*, v. 25, n. 5, p. 288–294, 2013.
- AHMED, Hassan; KUVA, Jukka.; PUNKKI, Jouni. Analysing entrapped pores in concrete via X-ray computed tomography: influence of workability and compaction time. *Construction and Building Materials*, v. 417, art. 135322, 2024. DOI: 10.1016/j.conbuildmat.2024.135322.
- ALMEIDA, Silvio. Análise do módulo de elasticidade estático e dinâmico do concreto de cimento Portland através de ensaios de compressão simples e de frequência ressonante. 2012. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2012.
- AMERICAN CONCRETE INSTITUTE. Building Code Requirements for Structural Concrete (ACI 318-19) and Commentary (ACI 318R-19). Farmington Hills, MI: American Concrete Institute, 2019.
- AMERICAN SOCIETY FOR TESTING AND MATERIALS. ASTM C642: Standard Test Method for Density, Absorption, and Voids in Hardened Concrete. West Conshohocken, 2009.
- AMORIM, Aline Jardim. Desenvolvimento de uma rede neuro-fuzzy para a previsão da carga. 2015. Dissertação (Mestrado) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2015.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 6118:2023: projeto de estruturas de concreto – procedimento. Rio de Janeiro: ABNT, 2023.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 9778: Argamassa e concreto endurecido – Determinação da absorção de água, índice de vazios e massa específica. Rio de Janeiro, 2018.
- ATHAYDE. Avaliação da penetração de íons cloreto em concretos produzidos com escória de alto forno e agregados miúdos reciclados de resíduo de concreto fresco. 2020. Dissertação (Mestrado) – Universidade Federal de Minas Gerais, Belo Horizonte, 2020.
- AZEVEDO, Álvaro. Método dos elementos finitos. Porto: Faculdade de Engenharia da Universidade do Porto, 2003.
- BADUGE, Shanaka Kristombu; MENDIS, Priyan; THILAKARATHNA, Sadeep; VIMONSATIT, Vanissorn. Multiscale modeling of concrete. Cambridge: Woodhead Publishing, 2025.
- BARBOSA, Anderson Henrique; FREITAS, Marcílio Sousa da Rocha; NEVES, Francisco de Assis das. Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais. *REM: Revista Escola de Minas, Ouro Preto*, v. 58, n. 3, p. 247–255, jul./set. 2005. DOI: 10.1590/S0370-44672005000300011.
- BARRETO, Jairo Orlando Fuentes; FÉLIX, Emerson Felipe. Aplicação de redes neurais artificiais para a predição do índice de vazios de concretos com e sem agregados de RCD. *IBRACON*. 2025.
- BATISTA, Bruna Caroline Campos; SILVA, Áquila Blanche Bastos Martins da; NOÉ, Amanda Freitas; LOPES, Raduan Krause; CHRISTOFORO, André Luis; ALMEIDA, Diego Henrique de. Influência da adição de RCD misto na resistência à compressão e na porosidade de argamassa. *Revista Principia*, v. 59, n. 3, p. 934–948, 2022. DOI: 10.18265/1517-0306a2021id5005.
- BATISTA, Maria Rita. A utilização de algoritmos de aprendizado de máquina em problemas de classificação. 2019. Dissertação (Mestrado) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2019.

BEHNOOD, Ali; OLEK, Jan; GLINICKI, Michał A. Predicting modulus elasticity of recycled aggregate concrete using M5' model tree algorithm. *Construction and Building Materials*, v. 94, p. 137–147, 2015. DOI: 10.1016/j.conbuildmat.2015.06.048.

BELOTTI, Jonatas. Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles. 2019. Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná, Curitiba, 2019.

BERMOND, Camila; MIRANDA, Renato Billia; TECH, Adriano Rogério Bruno; MAUAD, Frederico Fábio. Preenchimento de falhas em dados de precipitação através de métodos tradicionais e por inteligência artificial. *Revista Brasileira de Climatologia*, v. 28, p. 187–207, 2021. DOI: 10.5380/abclima.v28i0.78539.

BORGES, Danilo; QUARESMA, Wanessa; FERNANDES, Gabrielar; PITUBA, Júlio. Evaluation of a proposed model for concrete at mesoscopic scale. *Revista IBRACON de Estruturas e Materiais*, v. 10, n. 5, p. 1087–1112, set. 2017.

CANADIAN STANDARDS ASSOCIATION. CSA A23.3:24: Design of concrete structures. 8. ed. Mississauga, ON: CSA Group, 2024. Disponível em: <https://www.csagroup.org>. Acesso em: 19 jul. 2026.

CAO, Chong. Prediction of concrete porosity using machine learning. *Results in Engineering*, v. 17, art. 100818, 2023. DOI: 10.1016/j.rineng.2023.100818.

CARMO, Carlos; SILVA, Jessica. Aprendizado de máquina e prestação de serviços de armazenamento de dados: métricas para análise e validação de algoritmos previsores. *GETEC*, v. 12, 2023.

CARTUXO, Francisco; BRITO, Jorge de; EVANGELISTA, Luís; JIMÉNEZ, José Ramón; LEDESMA, Enrique F. Increased durability of concrete made with fine recycled concrete aggregates using superplasticizers. *Materials*, v. 9, n. 2, art. 98, 2016.

CODA, Humberto Breves; GRECO, Marcelo. A simple FEM formulation for large deflection 2D frame analysis based on position description. *Computer Methods in Applied Mechanics and Engineering*, v. 193, n. 33–35, p. 3541–3557, 2004. DOI: 10.1016/j.cma.2004.01.023.

CODA, Humberto Breves; PACCOLA, Rodrigo Ribeiro. A FEM procedure based on positions and unconstrained vectors applied to non-linear dynamic of 3D frames. *Finite Elements in Analysis and Design*, v. 47, n. 4, p. 319–333, 2011. DOI: 10.1016/j.finel.2010.11.004.

CODA, Humberto Breves; PACCOLA, Rodrigo Ribeiro. Unconstrained finite element for geometrical nonlinear dynamics of shells. *Mathematical Problems in Engineering*, v. 2009, art. 748940, p. 1–20, 2009. DOI: 10.1155/2009/748940.

CODA, Humberto Breves; PACCOLA. A FEM procedure based on positions and unconstrained vectors applied to non-linear dynamic of 3D frames. *Finite Elements in Analysis and Design*, v. 47, n. 4, p. 319–333, 2011. DOI: 10.1016/j.finel.2010.11.001.

CODA, Humberto Breves; PACCOLA. A positional FEM formulation for geometrical non-linear analysis of shells. In: CONGRESSO NACIONAL DE MECÂNICA COMPUTACIONAL (CILAMCE), 29., 2008. Anais... Maceió: ABMEC, 2008.

CODA, Humberto Breves; PACCOLA. Unconstrained finite element for geometrical nonlinear dynamics of shells. *Mathematical Problems in Engineering*, v. 2009, Article ID 575131, 2009. DOI: 10.1155/2009/575131.

COMITÉ EURO-INTERNATIONAL DU BÉTON; FÉDÉRATION INTERNATIONALE DE LA PRÉCONTRAÎNTE. CEB-FIP Model Code 1990: Design of Concrete Structures. London: Thomas Telford, 1993.

COSTA, Jose. Agregado reciclado de resíduos de construção e demolição: variabilidade e influência no comportamento mecânico do concreto. 2018. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 2018.

CUTLER, Adele; CUTLER Richard.; STEVENS, John. Random Forests. Ensemble Machine Learning. Springer, 2012. p. 157–175.

CYBENKOT. Approximation by superpositions of a sigmoidal function. Mathematics of Control, Signals, and Systems, v. 2, 1989.

DE CERQUEIRA, Eduardo; ANDRADE, João; POPPI, Ronei; MELLO, Cesar. Redes neurais e suas aplicações em calibração multivariada. Química Nova, São Paulo, v. 24, n. 6, p. 864–873, 2001. DOI: 10.1590/S0100-40422001000600025.

DEMIR, Fuat. A new way of prediction elastic modulus of normal and high strength concrete-fuzzy logic. Cement and Concrete Research, v. 35, n. 8, p. 1531–1538, ago. 2005.

DEMIR, Fuat. Prediction of elastic modulus of normal and high strength concrete by artificial neural networks. Construction and Building Materials, v. 22, n. 7, p. 1428–1435, jul. 2008.

EMERY, James; HOCHHALTER, Jeffrey; INGRAFFEA, Anthony. Computational Fracture Mechanics of Concrete Structures: A Retrospective through Multiple Lenses. Catania, 2007. Disponível em: www.teragrid.org.

ESTOLANO, Victor; FUCALÉ, Stela; VIEIRA FILHO, José Orlando; GABRIEL, Diego; ALENCAR, Yuri. Avaliação dos módulos de elasticidade estático e dinâmico de concretos produzidos com agregados reciclados oriundos de resíduos de pré-fabricados de concreto. Matéria (Rio de Janeiro), v. 23, n. 1, e11974, 2018.

FARIAS; RIBEIRO; SOUZA. Avaliação da influência do agregado graúdo de diferentes composições mineralógicas no módulo de elasticidade do concreto. 2018.

FEI, Zhengyu; LIANG, Shixue; CAI, Yiqing; SHEN, Yuanxie. Ensemble machine-learning-based prediction models for the compressive strength of recycled powder mortar. Materials, v. 16, n. 2, art. 583, 2023. DOI: 10.3390/ma16020583.

FÉLIX, Emerson Felipe; FALCÃO, Isabela; SANTOS, Gabriela; PRADO, Lisiane. A three-phase approach to modeling the mechanical behavior of concrete and predicting the elastic modulus. In: CONGRESSO LUSO-BRASILEIRO DE MATERIAIS DE CONSTRUÇÃO SUSTENTÁVEIS, 2024. Anais. 2024.

FELIX, Emerson Felipe; POSSAN, Edna; CARRAZEDO, Rogério. Artificial Intelligence Applied in the Concrete Durability Study. In: BAROGHEL-BOUNY, Véronique; WITTMANN, Folker H. (ed.). Hygrothermal Behaviour and Building Pathologies. Cham: Springer, 2021. p. 99–121. DOI: 10.1007/978-3-030-50998-9_5.

FÉLIX, Emerson Felipe. Estudo numérico-experimental da fadiga em concretos submetidos à compressão cíclica: proposição de um modelo de dano acumulado. 2022. Tese (Doutorado) – Universidade de São Paulo, São Carlos, 2022.

FÉLIX, Emerson Felipe. Modelagem da deformação do concreto armado devido à formação dos produtos de corrosão. 2018. Dissertação (Mestrado) – Universidade de São Paulo, São Carlos, 2018.

FÉLIX, Wilson Salomão. Aplicação de aprendizado por reforço em navegação de robôs. 2022. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2022.

FERREIRA, João Socorro. Elementos básicos de aprendizagem de máquina. *INTERMATHS*, v. 4, n. 2, p. 54–74, 30 dez. 2023.

FILHO, Fabio. Avaliação da resistência à compressão e ao ataque por ácido sulfúrico de concretos com agregados graúdos reciclados de idades distintas. 2021. Dissertação (Mestrado) – Universidade Estadual do Norte Fluminense, Campo dos Goytacazes, 2021.

FLECK, Leandro; TAVARES, Maria Hermínia Ferreira; EYNG, Eduardo; HELMANN, Andrieli Cristina; ANDRADE, Minéia Aparecida de Moares. Redes neurais artificiais: princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia, Medianeira*, v. 7, n. 15, p. 47–57, jan./jun. 2016.

FORTI, Tiago; BATISTELA, Gustavo; FORTI, Nadia; VIANNA, Nicolas. 3D mesoscale finite element modelling of concrete under uniaxial loadings. *Materials*, v. 13, n. 20, art. 4585, 2020. DOI: 10.3390/ma13204585.

FRANCHINI, Caroline. Análise técnica do uso de agregado graúdo reciclado misto em concreto convencional. 2021. Trabalho de Conclusão de Curso – Universidade de Caxias do Sul, Caxias do Sul, 2021.

FROTTÉ, Camila; DI NUBILA, Clarisse Sophia Alejandra; NAGALLI, André; MAZER, Wellington; MACIOSKI, Gustavo; OLIVEIRA, Luna Ollin Steffen de. Estudo das propriedades físicas e mecânicas de concreto com substituição parcial de agregado natural por agregado reciclado proveniente de RCD. *Revista Matéria*, v. 22, n. 2, e11871, 2017. DOI: 10.1590/S1517-707620170002.0143.

GAMIL, Yaser. Machine learning in concrete technology: a review of current researches, trends, and applications. *Frontiers in Built Environment*, v. 9, 2023. DOI: 10.3389/fbuil.2023.1145591.

GERIN, Mayara. Comportamento de pilares mistos preenchidos com concreto de resíduos de concreto submetidos a compressão axial centrada. 2020. Dissertação (Mestrado) – Universidade Federal de Minas Gerais, Belo Horizonte, 2020.

GIMENES, Marcela; RODRIGUES, Eduardo; BITENCOURT, Luís; MANZOLI, Osvaldo. 2D mesoscale modeling of compressive fracture in concrete using a mesh fragmentation technique. *International Journal of Solids and Structures*, v. 260-261, art. 112191, 2023.

GODOI, Wanessa. Estudo do comportamento mecânico do concreto com diferentes modelagens da zona de transição em elementos finitos na escala mesoscópica. In: CONGRESSO IBERO-LATINO-AMERICANO SOBRE MÉTODOS COMPUTACIONAIS PARA ENGENHARIA (CILAMCE), 37., 2016, Brasília. Anais [...]. Rio de Janeiro: ABMEC, 2016.

GOLAFSHANI, Emadaldin Mohammadi; BEHNOOD, Ali. Application of soft computing methods for predicting the elastic modulus of recycled aggregate concrete. *Journal of Cleaner Production*, v. 176, p. 1163–1176, 1 mar. 2018.

Gomes, Bárbara; LEONEL, Antônio Carlos; LIMA, Vitor Augusto Lopes; ARAÚJO, Daniel de Lima. Avaliação da resistência e do módulo de elasticidade de concretos convencionais e autoadensáveis submetidos a altas temperaturas. *Revista Eletrônica de Engenharia Civil*, v. 17, n. 1, p. 63–83, 2021.

GONG, Chun; LIU, Dunwen; CAO, Kunpeng; JIAN, Yinghua. Study on the spatiotemporal evolution and prediction of internal porosity in concrete specimens under sulfate attack based on machine learning models. *Results in Engineering*, v. 24, art. 103336, 2024.

GONZÁLEZ-TABOADA, Iris; GONZÁLEZ-FONTEBOA, Belén; MARTÍNEZ-ABELLA, Fernando; PÉREZ-ORDÓÑEZ, Juan Luis. Prediction of the mechanical properties of structural recycled concrete using multivariable regression and genetic programming. *Construction and Building Materials*, v. 106, p. 480–499, 2016.

GRASSL, Peter; JIRÁSEK, Milan. Meso-scale approach to modelling the fracture process zone of concrete subjected to uniaxial tension. *International Journal of Solids and Structures*, v. 47, n. 7–8, p. 957–968, abr. 2010.

HÄFNER, Stefan; ECKARDT, Stefan; LUTHER, Torsten; KÖNKE, Carsten. Mesoscale modeling of concrete: Geometry and numerics. *Computers & Structures*, v. 84, n. 7, p. 450–461, 2006.

HAYKIN, S. *Redes neurais: princípios e práticas*. 2. ed. Porto Alegre: Bookman, 2001.

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

HERNÁNDEZ, Juan Diego; PEÑALOZA, Elena. Sobre el uso adecuado del coeficiente de correlación de Pearson. *Revista Facultad de Ciencias de la Salud*, v. 37, 2018.

HERTZMANN, Aaron; FLEET, David. *Machine Learning and Data Mining: lecture notes*. Toronto: Department of Computer Science, University of Toronto, 2012. Disponível em: <https://www.dgp.toronto.edu/~hertzman/411notes.pdf>. Acesso em: 19 jul. 2026.

HORNIK, Kurt. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, v. 4, p. 251–257, 1991.

JENSEN, Ole Mejlhede.; HANSEN, Per. Water-entrained cement-based materials I. Principles and theoretical background. *Cement and Concrete Research*, v. 31, n. 4, p. 647–654, 2001.

JIN, Liu; YU, Wenxuan; DU, Xiuli; YANG, Wangxian. Meso-scale simulations of size effect on concrete dynamic splitting tensile strength: Influence of aggregate content and maximum aggregate size. *Engineering Fracture Mechanics*, v. 230, art. 106972, 2020.

JIVKOV, Andrey; ENGELBERG, Dirk; STEIN, Robert; PETKOVSKI, Mihail. Pore space and brittle damage evolution in concrete. *Engineering Fracture Mechanics*, v. 110, p. 378–395, 2013.

JÚNIOR. *Desenvolvimento e análise de concreto com utilização de resíduos sólidos reciclados como agregado*. 2021. Dissertação (Mestrado) – Universidade Federal do Ceará, Fortaleza, 2021.

KHAN; ASCE. *Permeation of High-Performance Concrete*. 2003.

KIM, Hyunwook; WAGONER, Michael; BUTTLAR, William. Micromechanical fracture modeling of asphalt concrete using a single-edge notched beam test. *Materials and Structures/Materiaux et Constructions*, v. 42, n. 5, p. 677–689, jun. 2009.

KNACK, Magdalena; NITKA, Michał; RUCKA, Magdalena. Discrete element method modelling of elastic wave propagation in a meso-scale model of concrete. *Ultrasonics*, v. 141, 1 jul. 2024.

KOOPAS, Najafi; RAUTER, Natalie; LAMMERING, Rolf. Two-Dimensional Mesoscale Finite Element Modeling of Concrete Damage and Failure. *Applied Sciences (Switzerland)*, v. 13, n. 15, 1 ago. 2023.

LE, Ba-Anh; VU, Viet-Hung; SEO, Soo-Yeon; TRAN, Bao-Viet; NGUYEN-SY, Tuan; LE, Minh-Cuong; VU, Thai-Son. Predicting the compressive strength and the effective porosity of pervious concrete using machine learning methods. *KSCE Journal of Civil Engineering*, v. 26, n. 11, p. 4664–4679, 2022. DOI: 10.1007/s12205-022-1918-z.

LEAL, Cleber Eduardo Fernandes; PARSEKIAN, Guilherme Aris; FERREIRA, Fernanda Giannotti da Silva; CHRISTOFORO, André Luis. Comparação entre módulos de deformação de concretos nacionais produzidos com agregados graúdos de diferentes origens mineralógicas. *Revista Matéria*, v. 25, n. 4, e-12952, 2020.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. DOI: 10.1038/nature14539.

LEE, Jaesung; XI, Yunping; WILLAM, Kaspar; JUNG, Younghun. A multiscale model for modulus of elasticity of concrete at high temperatures. *Cement and Concrete Research*, v. 39, n. 9, p. 754–762, 2009.

LI, Yi.; SHENG, Junlei; LI, Wei.; YU, Mengxuan.; ZHENG, Xiaotian.; WANG, Fuzhou. Effect of a novel spherical tailings aggregate on the macro- and mesoscopic properties of pervious concrete. *Cement and Concrete Composites*, v. 144, art. 105311, 2023. DOI: 10.1016/j.cemconcomp.2023.105311.

LIMA, Mayara da Silva; CHAVES, Maria Thereza Rocha; AGUIAR, Marcos Fábio Porto de; FARIAS, Teresa Raquel Lima. Influência do resíduo de construção e demolição como agregado na produção de concreto para pavimentos permeáveis. *Revista Principia*, v. 62, 2024. DOI: 10.18265/2447-9187a2024id8566.

LOPEZ, Ana Maria. Distribuição de frequência. SciELO Books, p. 6–13, 2010.

LOUBACK, Filipe; MATTOS, Juliana Barcellos; LOUBACK, Késia Alves Coelho; SIMONETTI, Domingos Sávio Lyrio; BATISTA, Oureste Elias. Previsão de indicadores de continuidade de energia elétrica a partir da aplicação do método de redes neurais artificiais. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA (CBA), 23., 2020, Porto Alegre. Anais [...]. Porto Alegre: SBA, 2020.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados*, v. 35, n. 101, p. 85–94, 1 jan. 2021.

LYU, Kai; GARBOCZI, ; LIU, Xiaoyan. A quantitative characterization of spatial arrangement of air voids in mortars via X-ray CT and numerical calculations. *Construction and Building Materials*, v. 360, art. 129550, 2022. DOI: 10.1016/j.conbuildmat.2022.129550.

LYU, Kai; GARBOCZI, Edward J.; SHE, Wei; MIAO, Changwen. The effect of rough vs. smooth aggregate surfaces on the characteristics of the interfacial transition zone. *Cement and Concrete Composites*, v. 99, p. 49–61, 1 maio 2019.

MACEDO, Josiane. Controle inteligente de sistemas eletro-hidráulicos utilizando redes neurais artificiais. 2012. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Norte, Natal, 2012.

MAIA, Poliana de Souza; SILVA JÚNIOR, Ladir Antônio da; SALLES, Pedro Valle; CARVALHO, Malheny Vitória Silva. Technical evaluation of structural concrete made with coarse aggregate from construction and demolition waste. *Research, Society and Development*, v. 11, n. 8, e45011830582, 2022. DOI: 10.33448/rsd-v11i8.30582.

MALEKI, Mirshad; RASOOLAN, Iraj; KHAJEHDEZFULY, Amin; JIVKOV, Andrey. On the effect of ITZ thickness in meso-scale models of concrete. *Construction and Building Materials*, v. 258, art. 119639, 2020.

MARMITTI, Benno Aluisio; BEZ, Anderson; DIDONE, Jorge Augusto; PACHECO, Thiago Loi; VALDAMERI, Cledison Zatta. Estudo comparativo de métodos para dosagem de concreto. In: Congresso Técnico Científico da Engenharia e da Agronomia. 2016.

MARTINELI, Edmar. Extração de conhecimento de redes neurais artificiais. 2003. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2003.

MAZONI, Ivan; TABORDA, Andreia. Comparação de materiais na engenharia civil: desempenho e sustentabilidade de estruturas de concreto, metal e madeira. Caderno Progressus, 2024.

MEIRELES, Priscila. Análise da influência da massa específica de agregados graúdos provenientes de resíduos de construção e demolição no desempenho mecânico do concreto. 2005. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

MITCHELL, Tom. Machine learning. New York: McGraw-Hill, 1997.

MORAES, Andre; SANTOS, Danilo. Aplicação de redes neurais artificiais na previsão da resistência à compressão de concretos produzidos com agregados reciclados. Revista AIDIS de Ingeniería y Ciencias Ambientales, p. 1484–1501, 2022. DOI: 10.22201/iingen.0718378xe.2022.15.3.81651.

MORETTI, Jose. Sistema inteligente baseado nas redes neurais artificiais para dosagem do concreto. 2010. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 2010.

MOURA SANTOS, Hannah. Estudo laboratorial sobre os danos causados pelo broqueamento e retificação em corpos-de-prova testemunhos. 2006. Dissertação (Mestrado) – Universidade Federal de Pernambuco, Recife, 2006.

MOURA, Camila. Aplicação de formulação baseada no Método dos Elementos Finitos Posicional na análise bidimensional elástica de compósitos particulados. 2015. Dissertação (Mestrado) – Universidade de São Paulo, São Carlos, 2015.

MUKHERJEE, Abhijit; BISWAS, Sudip Nag. Artificial neural networks in prediction of mechanical behavior of concrete at high temperature. Nuclear Engineering and Design, v. 178, n. 1, p. 1–11, 1997. DOI: 10.1016/S0029-5493(97)00152-0.

MUNGULE, Mahesh; RAGHUPRASAD. Meso-scale studies in fracture of concrete: A numerical simulation. jun. 2011.

MURSHIDA; JIYAD; NAGARAJAN, Praveen. Development of mesoscopic model for concrete – A critical review. Materials Today: Proceedings, 2023.

NEHME, Salem. The porosity of concrete and its analysis by neural networks. ResearchGate, 2000. Disponível em: <https://www.researchgate.net/publication/281069069>.

NETO, Aníbal Emiliano. Comparação de métodos de estimação de modelos de apreçamento de ativos. 2012. Dissertação (Mestrado) – Universidade de São Paulo, São Paulo, 2012.

NETO, Pompoe; OLIVEIRA, Denio; RAMOS, Danielli. Efeitos do tipo, tamanho e teor de agregado graúdo no módulo de deformação do concreto de alta resistência. Revista Matéria, 2023.

NEVILLE, Adam; BROOKS, Jeffrey. Concrete technology. New York: Prentice Hall, 2018.

NGUYEN, Vinh Phu; LLOBERAS-VALLS, Oriol; STROEVEN, Martijn; SLUYS, Lambertus Johannes. On the existence of representative volumes for softening quasi-brittle materials: A failure zone averaging scheme. Computer Methods in Applied Mechanics and Engineering, v. 199, n. 45–48, p. 3028–3038, 2010.

NGUYEN, Vinh Phu; STROEVEN, Martijn; SLUYS, Lambertus Johannes. Multiscale failure modeling of concrete: Micromechanical modeling, discontinuous homogenization and parallel computations. *Computer Methods in Applied Mechanics and Engineering*, v. 201–204, p. 139–156, 1 jan. 2012.

NIKOLIĆ, Mijo; KARAVELIĆ, Emir; IBRAHIMBEGOVIĆ, Adnan; MIŠČEVIĆ, Predrag. Lattice element models and their peculiarities. *Archives of Computational Methods in Engineering*, v. 25, n. 3, p. 753–784, 2018.

NOGUEIRA, Daniella; LIMA, Rafaela; GOMES Kiria. Influência do metacaulim para o tratamento do agregado graúdo reciclado de concreto. *Brazilian Journal of Development*, v. 6, n. 3, p. 15326–15339, 2020.

NUNES, Wesley Carlos. Influência do agregado graúdo reciclado de resíduos da construção predial nas propriedades do concreto fresco e endurecido. 2017. Dissertação (Mestrado) – Universidade Federal de Goiás, Goiânia, 2017.

OLIVEIRA, Marco Antônio Assis; FERREIRA, Marcelo Laédson Morato; SILVA JÚNIOR, Edmilson Roque da; ARAUJO, Deividy Kaik de Lima; LIMA, Danylo de Andrade. Análise da substituição do agregado graúdo por RCD em concretos. 2023. DOI: 10.55449/conresol.6.23.vii-005.

ORLANDI, Veridiana. Redes neurais artificiais: uma contribuição ao processo de decisões financeiras e uma aplicação na previsão de insolvência das organizações. 1997. Dissertação (Mestrado) – Universidade de São Paulo, São Carlos, 1997.

PACCOLA, Rodrigo; CODA, Humberto Breves. A direct FEM approach for particulate reinforced elastic solids. *Composite Structures*, v. 141, p. 282–291, 1 maio 2016.

PACCOLA; CODA, Humberto Breves. A direct FEM approach for particulate reinforced elastic solids. *Composite Structures*, v. 141, p. 282–291, 2016. DOI: 10.1016/j.compstruct.2016.01.062.

PACK, Leslie; MOORE, Andrew. Reinforcement learning: a survey. *Journal of Artificial Intelligence Research*, v. 4, p. 237–285, 1996. DOI: 10.1613/jair.301.

PAIXÃO, Joelson. Redes neurais artificiais: estrutura, modelagem matemática e exemplo de aplicação. In: *Inovações Multidisciplinares na Engenharia*. Aurum Editora Ltda., 2025. p. 12–22. DOI: 10.63330/aurumpub.005-002.

PEDRO, Daniel; DE BRITO, Jorge; EVANGELISTA, Luis. Influence of the use of recycled concrete aggregates from different sources on structural concrete. *Construction and Building Materials*, v. 71, p. 141–151, 2014.

PEDROSA, Edson. Propriedades físico-mecânicas do concreto de cimento Portland contendo resíduo vítreo como agregado miúdo. 2012. Dissertação (Mestrado) – Instituto Federal do Maranhão, São Luís, 2012.

PIMENTEL, Pamela; BITTENCOURT, Felipe. Análise da resistência do concreto convencional com substituição parcial do agregado natural por agregado de polietileno tereftalato (PET) com uso de aditivo. 2018.

PIOVESAN, Jayne Carlos. Otimização multivariada da substituição de agregados de resíduos de construção e demolição em concreto. 2016. Dissertação (Mestrado) – Universidade Federal do Amazonas, Manaus, 2016.

PRAYOGO, D.; SANTOSO, D. I.; WIJAYA, D.; GUNAWAN, T.; WIDJAJA, J. A. Prediction of concrete properties using ensemble machine learning methods. *Journal of Physics: Conference Series*, v. 1625, n. 1, art. 012024, 2020. DOI: 10.1088/1742-6596/1625/1/012024.

RAMOS, Éverton Souza; CARRAZEDO, Rogério; PACCOLA, Rodrigo Ribeiro. Modeling particles elements in damaged reinforced concrete structures. *Latin American Journal of Solids and Structures*, v. 18, n. 1, p. 1–24, 2021.

RAMOS, Everton.; CARRAZEDO, Rogerio; PACCOLA, Rodrigo. Modeling particles elements in damaged reinforced concrete structures. *Latin American Journal of Solids and Structures*, v. 18, n. 1, p. 1–24, 2021. DOI: 10.1590/1679-78256251.

RAUBER, Thomas Walter. *Redes neurais artificiais*. Vitória: Departamento de Informática, Universidade Federal do Espírito Santo, 2014. Disponível em: <<https://www.researchgate.net/publication/228686464>>.

RIVERA, Salvador. *Breve introducción a la teoría de errores y la graficación*. 2017.

RODRIGUES, Eduardo A.; MANZOLI, Osvaldo L.; BITENCOURT JR., Luís A. G.; BITTENCOURT, Tulio N. 2D mesoscale model for concrete based on the use of interface element with a high aspect ratio. *International Journal of Solids and Structures*, v. 94–95, p. 112–124, 2016.

RODRIGUES, Eduardo Alexandre. *Um modelo multiescala concorrente para representar o processo de fissuração do concreto*. Tese (Doutorado). São Paulo: Escola Politécnica da Universidade de São Paulo, 1 dez. 2015.

RODRIGUES, Eduardo; MANZOLI, Osvaldo; BITENCOURT, Luis.; BITTENCOURT, Tulio. 2D mesoscale model for concrete based on the use of interface element with a high aspect ratio. *International Journal of Solids and Structures*, v. 94–95, p. 112–124, 2016. DOI: 10.1016/j.ijsolstr.2016.05.004.

RODRÍGUEZ-BRITO, Natalia; BLANCO-PENÁLVER, Concepcion; SOUTO, Ricardo; ANDRADE, Carmen; SANTANA, Juan. Reassessment of porosimetry determinations using water vapor sorption measurements for pastes and concretes containing basaltic aggregates compared to the mercury intrusion method. *Materials*, v. 18, n. 10, art. 2257, 2025. DOI: 10.3390/ma18102257.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, Washington, DC, v. 65, n. 6, p. 386–408, 1958.

ROSENBLATT. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, n. 6, p. 386–408, 1958.

RUMELHART, David; HINTON, Geoffrey.; WILLIAMS, Ronald. Learning representations by back-propagating errors. *Nature*, v. 323, n. 6088, p. 533–536, 1986. DOI: 10.1038/323533a0.

SALVINO, Laís Régis. *Eficiência energética em sistemas pressurizados de distribuição de água com o uso de redes neurais artificiais*. 2018. Tese (Doutorado em Engenharia Mecânica) – Centro de Tecnologia, Universidade Federal da Paraíba, João Pessoa, 2018. Disponível em: <https://repositorio.ufpb.br/jspui/handle/123456789/12957>. Acesso em: 19 jul. 2026.

SANTOS, Larissa Gabriela dos; FALCÃO, Isabela da Silva; FÉLIX, Emerson Felipe; PRADO, Lisiane Pereira. Predição do índice de vazios de concretos com RCD: proposição de modelo baseado em aprendizado de máquina e validação experimental. In: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2024. Anais [...]. 2024.

SCHLANGEN; VAN MIER. Experimental and numerical analysis of micromechanisms of fracture of cement-based composites. *Cement and Concrete Composites*, v. 14, n. 2, p. 105–118, 1992.

SCHLEDER, Gabriel; FAZZIO, Adalberto. Machine Learning in Physics, Chemistry, and Materials Science: Materials Discovery and Design. *Revista Brasileira de Ensino de Física*, v. 43, p. 1–18, 1 jun. 2021.

SHAHBAZI, Siamak; RASOOLAN, Iraj. Meso-scale finite element modeling of non-homogeneous three-phase concrete. *Case Studies in Construction Materials*, v. 6, p. 29–42, 1 jun. 2017.

SILVA, Carla.; CAPUZZO, Valdirene. Evaluation of the durability of concretes produced with recycled concrete aggregates using the two-stage mixing approach. *Revista Materia*, v. 25, n. 1, 2020. DOI: 10.1590/s1517-707620200001.0882.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. *Redes neurais artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.

SILVA, Jamilly Alfano; SANTOS, Vinicius Daniel de Oliveira; VIANA, Danilo Fernandes; ARAÚJO, Raiane Sodré de. Concreto reciclado: a importância de inserção de práticas sustentáveis para reduzir os impactos ambientais e econômicos da construção civil. *Research, Society and Development*, v. 11, n. 17, e230111739180, 2022. DOI: 10.33448/rsd-v11i17.39180.

SILVA, Jessica. Comportamento sob altas temperaturas de concretos com agregados reciclados de concreto. 2017. Dissertação (Mestrado) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2017.

SILVA, Marcello Congro. Modelagem Numérica do Comportamento Mecânico de Materiais Compósitos Cimentícios em uma Abordagem Multiescala. Dissertação (mestrado)—Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 27 jan. 2020.

SILVA, Paulo DA. Controle de uma Coluna de Destilação Aplicando Redes Neurais. Dissertação — Uberaba-Mg: Universidade de Uberaba, 2018.

SILVA, Renato; ALMEIDA, Tiago; YAMAKAMI, Akebo. Análise de desempenho de redes neurais artificiais para classificação automática de web spam. *ResearchGate*, 2012.

SILVA; SPATTI; FLAUZINO. *Redes neurais artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.

SOUZA, Rafael Eller; ASSIS, João Batista Santos; VIEIRA, Davi Henrique Tomé Kanno; GRANATO, Leonardo Carlos; ASSIS, Paulo Santos. Hidratação do concreto adicionando cinza da casca de café. In: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2023. São Paulo: IBRACON, 2023. p. 2291–2303. DOI: 10.5151/2594-5327-40402.

SPRIGGS. Expression for effect of porosity on elastic modulus of polycrystalline refractory materials, particularly aluminum oxide. *Journal of the American Ceramic Society*, v. 44, n. 12, p. 628–629, 1961. DOI: 10.1111/j.1151-2916.1961.tb11671.x.

SUGASAWA, Shonosuke; NOMA, Hisashi. Estimating individual treatment effects by gradient boosting trees. *Statistics in Medicine*, v. 38, n. 26, p. 5146–5159, 20 nov. 2019.

TEDESCO, Marina. Estudo da utilização de resíduo de casca cerâmica de microfusão no concreto em substituição ao agregado gráudo e miúdo natural. 2016. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

TENÓRIO, Jonathas. Avaliação de propriedades do concreto produzido com agregados reciclados de resíduos de construção e demolição visando aplicações estruturais. 2007. Dissertação (Mestrado) – Universidade Federal de Alagoas, Maceió, 2007.

THILAKARATHNA, Petikirige Sadeep Madhushan; BADUGE, Kasun Shanaka Kristombu; MENDIS, Priyan; VIMONSATIT, Vanissorn; LEE, Hyuk. Mesoscale modelling of concrete – A review of geometry generation, placing algorithms, constitutive relations and applications. *Engineering Fracture Mechanics*, Elsevier Ltd, 15 maio 2020.

TOPÇU, Ilker Bekir. Alternative estimation of the modulus of elasticity for dam concrete. *Cement and Concrete Research*, v. 35, n. 11, p. 2199–2202, nov. 2005.

UGIONI, Vinicius; SANTOS, Daine. Análise das propriedades mecânicas do concreto produzido com substituições parciais e totais dos agregados graúdos e miúdos por agregados reciclados. Criciúma: UNESC, 2017.

ULRIK NILSEN, Abstract; MONTEIRO, Paulo. Concrete: a three-phase material. *Cement and Concrete Research*, v. 23, n. 1, p. 147–151, 1993. DOI: 10.1016/0008-8846(93)90145-Y.

UYYSAL, Mucteba; TANYILDIZI, Harun. Predicting the core compressive strength of self-compacting concrete (SCC) mixtures with mineral additives using artificial neural network. *Construction and Building Materials*, v. 25, n. 11, p. 4105–4111, nov. 2011.

VAN MIER, Jan. Fracture processes of concrete: Assessment of material parameters for fracture models. 1. ed. Florida: CRC, 1996. v. 1.

VANALLI, Leandro. O MEC e o MEF aplicados à análise de problemas viscoplásticos em meios anisotrópicos e compostos. Tese—São Carlos: Universidade de São Paulo, 2004.

VASCONCELLOS, Alex. Estudo da variabilidade do módulo de elasticidade de concretos produzidos com diferentes tipos de agregados graúdos. 2018. Dissertação (Mestrado em Engenharia Civil) – Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2018.

VIDYA SAGAR, Rudraraju; PRASAD, Raghu; NAZREEN; SINGH, Ram Kumar. Modeling mode-I fracture process in concrete at meso-scale: Computational aspects of lattice model and a comparison between results of two dimensional lattice simulation and acoustic emission measurements. *Engineering Fracture Mechanics*, v. 210, p. 257–278, 1 abr. 2019.

VIEIRA, Tiago; ALVES, André Vaz; BRITO, Jorge; CORREIA, João Pedro; SILVA, Rui Vasco Pacheco Santos. Durability-related performance of concrete containing fine recycled aggregates from crushed bricks and sanitary ware. *Materials & Design*, v. 90, p. 767–776, 2016.

VIEIRA, Welington Hilário; CODA, Humberto Breves; PACCOLA, Rodrigo Ribeiro. A direct FEM approach to model mesoscale concrete and connect non-matching meshes in multiscale analysis. *Revista IBRACON de Estruturas e Materiais*, IBRACON - Instituto Brasileiro do Concreto, 2024.

VIEIRA, Welington Hilário. Sobre o estudo de modelos numéricos aplicados à simulação multiescala do comportamento de estruturas de concreto. Dissertação (Mestrado)—São Carlos: Universidade de São Paulo, Escola de Engenharia de São Carlos, 25 mar. 2021.

VIEIRA, Welington; CODA, Humberto Breves; PACCOLA, Rodrigo. A direct FEM approach to model mesoscale concrete and connect non-matching meshes in multiscale analysis. *Revista IBRACON de Estruturas e Materiais*, v. 17, n. 1, 2024. DOI: 10.1590/S1983-41952024000100011.

VIEIRA, Welington; PACCOLA, Rodrigo; CODA, Humberto Breves. Crack analysis of mesoscale concrete by FEM using an alternative mesh overlay to represent mortar and coarse aggregate. 2021.

VIEIRA, Welington. Sobre o estudo de modelos numéricos aplicados à simulação multiescala do comportamento de estruturas de concreto. 2021. Dissertação (Mestrado em Engenharia de Estruturas) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2021.

VILARDELL; AGUADO, Antonio; AGULLÓ, Luis; GETTU, Ravindra. Estimation of the modulus of elasticity for dam concrete. *Cement and Concrete Research*, v. 28, n. 1, p. 93–101, 1998. DOI: 10.1016/S0008-8846(97)00214-7.

WANG, Xiaofei; YANG, Zhi Jian; YATES, John R.; JIVKOV, Andrey P.; ZHANG, Chunsheng. Monte Carlo simulations of mesoscale fracture modelling of concrete with random aggregates and pores. *Construction and Building Materials*, v. 75, p. 35–45, 2015.

WANG, Xiaofeng; JIVKOV, Andrey. Combined Numerical-Statistical Analyses of Damage and Failure of 2D and 3D Mesoscale Heterogeneous Concrete. *Mathematical Problems in Engineering*, v. 2015, 2015.

WEI, Shuaishuai; ZHANG, Huan; WANG, Ding.; WANG, Xuchun.; CAO, Mengdi. Mesoscale mechanical analysis of concrete based on a 3D random aggregate model. *Coatings*, v. 15, n. 8, art. 883, 2025. DOI: 10.3390/coatings15080883.

WIDDROW; HOFF. Adaptive Switching Circuits. IRE WESCON Convention Record, 1960.

WIENS, Matthew; VERONE-BOYLE, Alissa; HENSCHIED, Nick; PODICHETTY, Jagdeep T.; BURTON, Jackson. A tutorial and use case example of the eXtreme Gradient Boosting (XGBoost) artificial intelligence algorithm for drug development applications. *Clinical and Translational Science*, v. 18, n. 3, e70172, 2025.

WILSON; CARTER; HOFF. British Standard and RILEM water absorption tests: a critical evaluation. *Materials and Structures*, v. 32, n. 8, p. 571–578, 1999.

XU, Chenyang; LI, Qiuyi; WANG, Peihan; FAN, Qianqian; KONG, Zhe; WANG, Lliang; YUE, Gongbing; ZHENG, Shidong; SHAO, Changhai; GUO, Yuanxin. Theoretical porosity design, mechanical properties, and durability of large-pore sandy recycled concrete. *Case Studies in Construction Materials*, v. 21, art. e03655, 2024. DOI: 10.1016/j.cscm.2024.e03655.

YANG, Lifu; YIN, Hao; SU, Huaizhi; YAO, Kefu.; ALNAGGAR, Mohammed; DI LUZIO, Giovanni.; CUSATIS, Gianluca. A multiscale homogenization approach for multiphysics lattice modeling of alkali-silica reaction in concrete: upscaling coupled mechanics and mass transport. *Cement and Concrete Research*, v. 205, art. 108230, 2026. DOI: 10.1016/j.cemconres.2026.108230.

YU, Kelai; QING, Longbang; HU, Yu. The effects of specimen size and aggregate on the evolution of the fracture process zone in concrete: A mesoscale investigation. *Composite Structures*, v. 355, p. 118852, fev. 2025.

YU, Yong; ZHENG, Yu; ZHAO, Xin Yu. Mesoscale modeling of recycled aggregate concrete under uniaxial compression and tension using discrete element method. *Construction and Building Materials*, v. 268, 25 jan. 2021.

ZHANG, Longfei; XIE, Hao; FENG, Jili. Mesoscale modeling and failure mechanism of concrete considering pore structures and actual aggregate shapes. *Construction and Building Materials*, v. 353, 24 out. 2022.

ZHANG, Zihua; GUO, Jialong; ZHANG, Zhenwen; SONG, Xiaogang. Mesoscale damage modelling of concrete by using image-based scaled boundary finite element method. *International Journal of Damage Mechanics*, v. 30, n. 8, p. 1281–1311, 2021.

ZHENG, Yuanxun; ZHANG, Yu; ZHUO, Jingbo; ZHANG, Peng; HU, Shaowei. Mesoscale synergistic effect mechanism of aggregate grading and specimen size on compressive strength of concrete with large aggregate size. *Construction and Building Materials*, v. 367, art. 130319, 2023.

ZHOU, Chunsheng; LI, Kefei; MA, Fu. Numerical and statistical analysis of elastic modulus of concrete as a three-phase heterogeneous composite. *Computers and Structures*, v. 139, p. 33–42, 15 jul. 2014.

ZHOU, Rongxin; SONG, Zhenhuan; LU, Yong. 3D mesoscale finite element modelling of concrete. *Computers and Structures*, v. 192, p. 96–113, 1 nov. 2017.

ZHOU, Yuliang; JIN, Hao; WANG, Binglong. Modeling and mechanical influence of meso-scale concrete considering actual aggregate shapes. *Construction and Building Materials*, v. 228, 20 dez. 2019.

ZHU, Chunquin; ZHU, Eryu; WANG, Bin; LI, Jiacheng; YAO, Tong; ZHANG, Zhu. Effect of porosity and pore size on the axial compressive properties of recycled aggregate concrete. *Materials*, v. 18, n. 12, art. 2830, 2025. DOI: 10.3390/ma18122830.

ZHU, Xing Yi; CHEN, Long. Numerical prediction of elastic modulus of asphalt concrete with imperfect bonding. *Construction and Building Materials*, v. 35, p. 45–51, out. 2012.