





Aprendizado de máquina para predição de resistência à compressão de argamassas com e sem resíduo de construção

Machine learning to predict the compressive strength of mortars with and without construction waste

Nilson Jorge Leão Júnior¹, Raniere Moisés da Cruz Fonseca¹ , Sergio Francisco da Silva¹ ,
Antover Panazzolo Sarmento¹ , Luiz Henrique Ferreira Rezio¹, Wanderlei Malaquias Pereira Junior¹ 

¹Universidade Federal de Catalão. Setor universitário, 75705-220, Catalão, GO, Brasil.

e-mail: nilsonjorge@discente.ufcat.edu.br, raniere.fonseca@ufcat.edu.br, sergio@ufcat.edu.br, antoverps@ufcat.edu.br, luiz_rezio@discente.ufcat.edu.br, wanderlei_junior@ufcat.edu.br

RESUMO

O presente trabalho objetivou avaliar o desempenho de algoritmos de aprendizado de máquinas na predição da resistência à compressão de argamassas. A base de dados foi criada através de uma busca bibliográfica de mais de 50 referências que foram catalogadas para conter dados de dosagens de argamassa com ou sem adição de resíduos de construção e demolição (RCD). O conjunto de dados avaliado passou por um pré-processamento de integração dos dados de resíduo de construção e demolição, e normalização. Como normalização optou-se pelo uso da técnica *z-score*. Em seguida, os algoritmos de Aprendizado de Máquina (AM): regressões linear e polinomial, árvores de decisão, *ensembles* e redes neurais foram utilizados para a predição da resistência à compressão. O conjunto de dados foi separado em 80% para treino e validação e 20% para teste. A validação cruzada empregada foi do tipo *k-fold* com 10 divisões no subconjunto de treino. Avaliando o desempenho dos modelos o algoritmo tipo *ensemble Gradient Boosting* apresentou o melhor desempenho quando comparado aos demais, atingindo um valor superior a 90% no coeficiente de determinação. Por fim, conclui-se que o AM é uma ferramenta prática importante na predição da resistência à compressão de argamassas. Além disso, o modelo de inteligência artificial foi prototipado para uso da comunidade científica e técnica em uma versão web disponível através do *framework* Streamlit da linguagem Python.

Palavras-chave: Inteligência Artificial; Argamassas; Agregado de Resíduos; Predição; Resíduos de Construção e Demolição.

ABSTRACT

The present work aimed to evaluate the performance of machine learning algorithms in predicting the compressive strength of mortars. The database was created through a bibliographic search of more than 50 references that were cataloged to contain data on mortar dosages with or without the addition of construction waste. The dataset used in the experiments underwent preprocessing, which included the integration of construction and demolition waste data and normalization. For normalization, the *z-score* technique was chosen. Then, the algorithms, linear regressions, decision trees, ensembles, and neural networks were used to predict compressive strength. The dataset was separated into 80% for training and validation and 20% for testing. The cross-validation was of the *k-fold* type with ten divisions in the training subset. Evaluating the performance of the models, the ensemble Gradient Boosting algorithm showed the best performance when compared to the others, reaching a value greater than 89% in the coefficient of determination. Finally, it is concluded that Machine Learning (ML) is a practical calculation tool for predicting the compressive strength of mortars. Furthermore, the artificial intelligence model was prototyped for the scientific and technical community use in a web version available through the Python Streamlit framework.

Keywords: Artificial Intelligence; Mortars; Waste Aggregate; Prediction; Construction and Demolition Waste Data.

1. INTRODUÇÃO

A construção civil é de extrema importância para a economia dos países, por ser grande geradora de empregos e movimentar toda uma cadeia de suprimentos. Estima-se que 50% das extrações de recursos naturais no mundo estão ligadas à indústria da construção, bem como é responsável pelo consumo de 40% de toda energia consumida e pela geração de 50% do total de resíduos sólidos produzidos [1].

Dentre os materiais de maior destaque na construção civil estão os materiais cimentícios como concreto e argamassa. Tais materiais têm grande destaque no cenário [2–5], sendo que o concreto é dado como o segundo material mais empregado após a água.

Um dos grandes desafios atuais da indústria da construção civil é a utilização e a aplicação dos conceitos de sustentabilidade. Uma das principais formas que vêm sendo pesquisada para se diminuir a pegada ambiental da construção civil é a reutilização de diferentes resíduos nas misturas cimentícias [6–8]. CARASEK *et al.* [9] apresenta que atrelado ao grande consumo de materiais há o exaurimento das jazidas de extração de agregado natural, acarretando assim no crescimento da utilização de agregado artificial. No Brasil em 2.022 foram coletados 48 milhões de toneladas de Resíduos de Construção e Demolição (RCD) [10], tal quantidade é referente apenas a dados coletados em empresas associadas, podendo estimar uma produção anual ainda maior, em decorrência da ocorrência de descarte irregular. Ante isso, a utilização de RCD na produção de agregado artificial reciclado se torna viável economicamente e ambientalmente correto.

Embora algumas pesquisas tratem da adição de agregados reciclados [11] nas misturas de argamassa, o custo, tempo de realização e validação dos traços tornam sua aplicação inviável à indústria da construção. Para que seja possível a utilização de agregados reciclados na argamassa, torna-se necessária a utilização de métodos robustos para a predição da resistência à compressão, bem como de suas demais características, e que apresente resultados confiáveis e com rapidez [12].

O uso de algoritmos de aprendizagem de máquina (AM) na predição da resistência de argamassas está diretamente ligado aos desafios enfrentados por laboratórios e pesquisadores da área de materiais de construção. Tradicionalmente, a determinação da resistência de argamassas depende de ensaios físicos demorados e onerosos, quando pensamos em dosar e testar novos materiais, destaca-se o tempo necessário para preparar, curar e testar quantidades elevadas de amostras para fornecer dados em tempo hábil, o que é crucial para decisões rápidas [13]. No caso deste trabalho destaca-se a relevância da determinação da resistência à compressão que é a variável a ser investigada [14].

A aplicação de AM permite uma previsão em tempo real, possibilitando ajustes rápidos no processo de mistura e aplicação da argamassa, otimizando recursos e reduzindo desperdícios. Isso não só acelera o processo de tomada de decisão, mas também pode levar a uma melhoria na qualidade do produto final. A longo prazo, a integração de AM pode reduzir custos operacionais e aumentar a eficiência dos laboratórios de materiais de construção, posicionando-os melhor para atender às demandas crescentes da indústria, apresentando novas abordagens e ferramentas para testar e prever propriedades de materiais, dando um direcionamento para pesquisadores e profissionais da área [15].

A aplicação de técnicas de IA nesse contexto oferece inúmeras vantagens, incluindo a promoção da sustentabilidade por meio da redução do uso de matéria prima, a diminuição de custos associados a testes laboratoriais extensivos, o direcionamento mais eficiente de ensaios no laboratório e a obtenção de ganhos significativos em agilidade e eficiência no processo de desenvolvimento de materiais de construção [16, 17].

A sustentabilidade é um tema central na engenharia civil contemporânea, e a utilização de IA para prever a resistência mecânica de argamassas contribui para a redução do desperdício de materiais, ao permitir a formulação de misturas mais precisas e eficientes. Além disso, a aplicação de IA nesse contexto pode resultar em uma diminuição significativa dos custos associados aos testes laboratoriais, uma vez que a predição computacional pode reduzir a necessidade de ensaios empíricos extensivos, otimizando o uso de recursos e insumos [13, 18].

De tal forma, o objetivo desta pesquisa foi investigar modelos de predição de resistência à compressão para argamassas tradicionais e, ou, com a utilização de agregados artificiais e de resíduos da construção civil, utilizando técnicas de aprendizado de máquina. A abordagem deste problema tem uma característica de problema inverso visto que um banco de dados será informado e pretende-se determinar uma característica mecânica como é o caso da resistência à compressão. Tal tipo de abordagem pode ser vista em PEREIRA JUNIOR *et al.* [2, 3].

2. MATERIAIS E MÉTODOS

Esta seção descreve os procedimentos necessários para a construção de modelos preditores da resistência mecânica da argamassa. Seguindo o procedimento informado em CRUVINEL *et al.* [19], a primeira fase deste

estudo é iniciada pela construção de um banco de dados relacionado à dosagem da argamassa. Já a segunda parte desta seção descreve os procedimentos de inteligência computacional aplicados neste artigo.

2.1. Descrição dos dados

O conjunto de dados estudado resulta da coleta e da integração de diferentes origens de fontes bibliográficas. A Tabela 1 apresenta o resumo dos dados e neste caso constam de 370 leituras de propriedades de dosagem e resistência mecânica.

Antes de gerar a estatística do conjunto de dados foi efetuada uma limpeza e organização no Banco de Dados (BD), para assim formar única referência de amostras com sete atributos de entrada referentes à dosagem da argamassa e um atributo de saída referente à resistência característica à compressão (*RES*).

A limpeza e organização efetuada consiste na criação da coluna RCD (Resíduos de Construção e Demolição) resultante da junção das variáveis de rejeito de marmoraria (RBMG) e areia de artificial de resíduo (AR). Além disso, possíveis duplicatas foram eliminadas. O BD não constava de valores ausentes antes da limpeza. A Tabela 2 apresenta uma descrição estatística do conjunto de dados após o tratamento e a Figura 1 mostra o histograma dos atributos que formam a base de dados.

A obtenção de resultados satisfatórios quanto à aplicação de qualquer tipo de argamassa na fase de dosagem é essencial. Esta fase consiste na caracterização e proporcionamento dos materiais constituintes da mistura argamassada, sendo que o produto do processo fornece a quantidade dos materiais que compõem a argamassa para atingir determinadas propriedades físicas e mecânicas. CARASEK [73], RECENA [74] e SABBATINI [75]

Tabela 1: Fonte de dados utilizados para a predição da resistência mecânica.

FONTE	QUANTIDADE DE AMOSTRAS	FONTE	QUANTIDADE DE AMOSTRAS
SILVA NETO <i>et al.</i> [20]	8	SILVA [21]	1
LARA <i>et al.</i> [22]	2	ARAÚJO [23]	24
TOKARSKI <i>et al.</i> [24]	3	CHEAH e RAMLI [25]	4
LEE e RAO [26]	2	POLAD <i>et al.</i> [27]	1
APOLINÁRIO [28]	24	SILVA <i>et al.</i> [29]	2
MOURA [30]	5	FORMIGONI e PAVEI [31]	1
TRENTIN <i>et al.</i> [32]	4	GUERRA e LUZ [33]	3
RIBEIRO [34]	4	PIMENTEL <i>et al.</i> [35]	6
PCZIECZEK <i>et al.</i> [36]	1	MUZARANA e POSSAN [37]	9
SANTOS <i>et al.</i> [38]	5	BONFIM <i>et al.</i> [39]	2
MARVILA <i>et al.</i> [40]	24	FERRARI <i>et al.</i> [41]	1
KURZ <i>et al.</i> [42]	2	AGRAWAL <i>et al.</i> [43]	54
MORICONI [44]	6	MOHAMMADHOSSEINI <i>et al.</i> [45]	3
AMIN <i>et al.</i> [46]	4	RAMJAN <i>et al.</i> [47]	2
SINGH <i>et al.</i> [48]	4	BU <i>et al.</i> [49]	12
NING <i>et al.</i> [50]	4	MAHIR MAHMOD <i>et al.</i> [51]	1
AADI <i>et al.</i> [52]	3	LI <i>et al.</i> [53]	4
LI <i>et al.</i> [54]	4	PATEL <i>et al.</i> [55]	3
ZHAO <i>et al.</i> [56]	4	DEMIR <i>et al.</i> [57]	5
NARS <i>et al.</i> [58]	4	RAINI <i>et al.</i> [59]	15
JUSTO-REINOSO <i>et al.</i> [60]	6	AZEVEDO <i>et al.</i> [61]	4
ABADOU <i>et al.</i> [62]	28	KABEER e VYAS [63]	10
SELVAJANRAN <i>et al.</i> [64]	2	CHAHOUR e SAFI [65]	15
SINGH CHOUHAN <i>et al.</i> [66]	3	SAFI <i>et al.</i> [67]	3
KABAY <i>et al.</i> [68]	3	YUN <i>et al.</i> [69]	3
CHEBOUB <i>et al.</i> [70]	5	HUANG <i>et al.</i> [71]	9
FERREIRA <i>et al.</i> [72]	9		

Tabela 2: Características estatísticas dos atributos do conjunto de dados após pré-processamento.

	CI	CA	AN	RCD	ADI	AG	CURA	RES
UNIDADE	kg/m ³	kg/m ³	kg/m ³	kg/m ³	kg/m ³	kg/m ³	dias	MPa
MÉDIA	448,75	52,81	1197,58	301,85	0,39	321,94	31,88	20,63
DESVIO	300,30	134,46	672,51	488,03	1,38	150,16	33,29	18,79
MIN	136,49	0,00	0,00	0,00	0,00	102,92	1,00	0,54
25%	244,11	0,00	945,00	0,00	0,00	262,43	7,00	5,00
50%	450,00	0,00	1320,80	0,00	0,00	307,98	28,00	14,46
75%	527,89	0,00	1534,44	426,75	0,00	315,00	28,00	31,87
MAX	2616,67	1338,54	5273,00	2250,00	10,60	1570,00	360,00	76,90

Cimento (CI); Cal (CA); Areia Natural (AN); Resíduos de Construção e Demolição (RCD); Aditivo plastificante (ADI); Água (AG); Tempo (CURA); Resistência à compressão (RES).

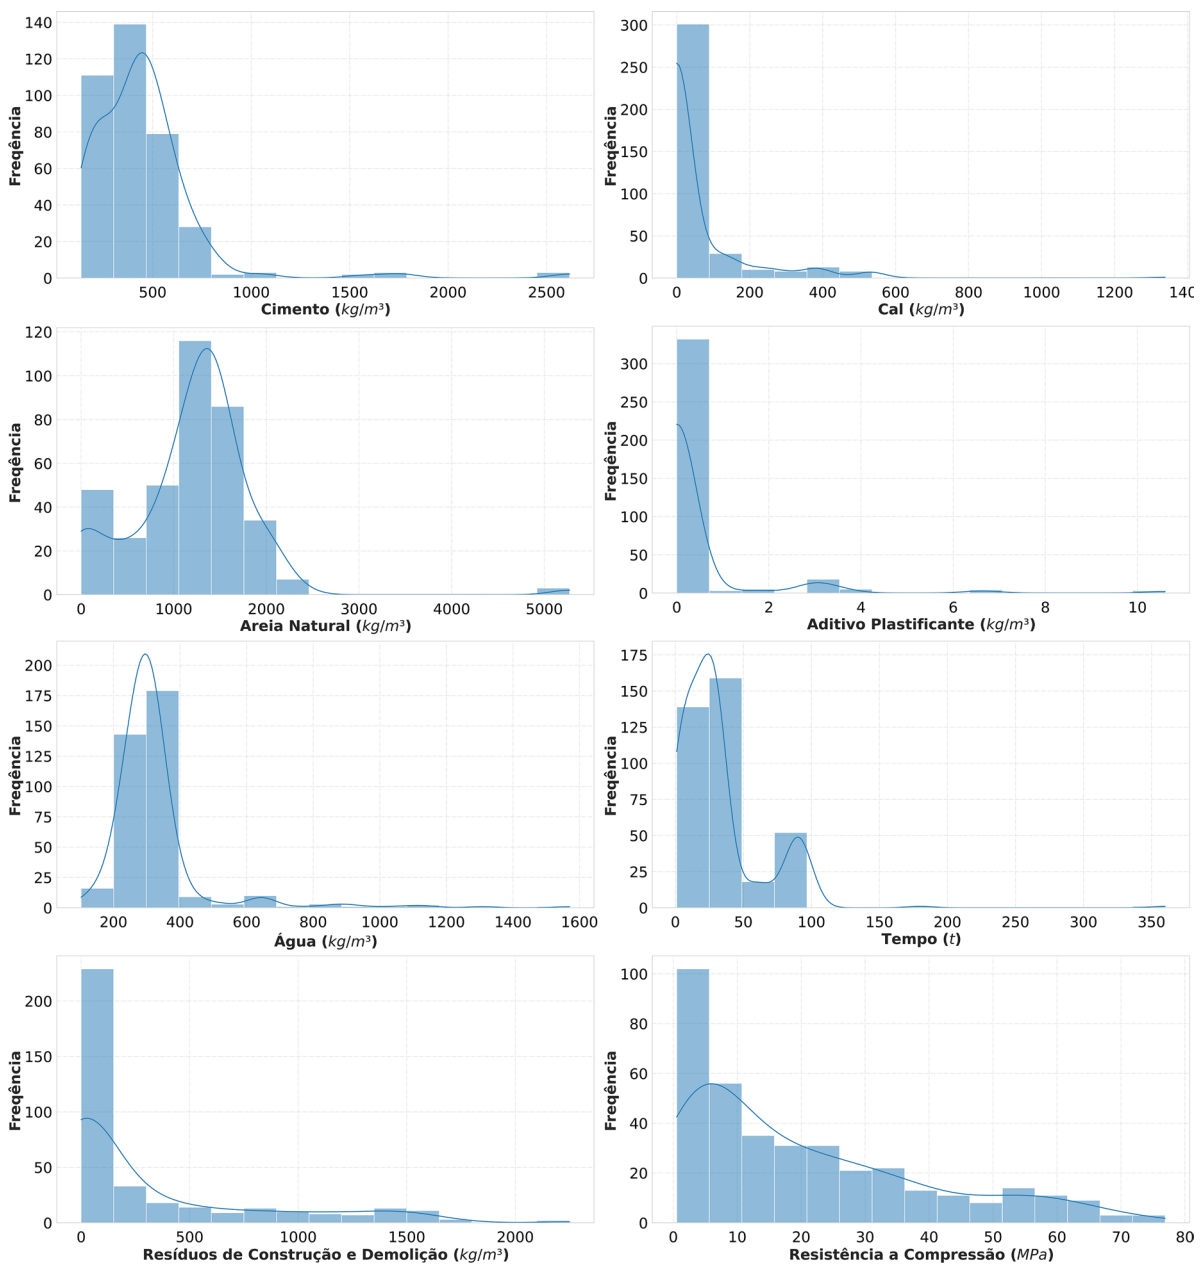


Figura 1: Distribuição das variáveis do banco de dados.

apresentam as propriedades requeridas em argamassas: trabalhabilidade, retenção de água, retração na secagem, aderência, absorção de deformações e resistência à compressão.

O estudo da dosagem das argamassas é essencial para que as variáveis referentes à qualidade e o custo de execução sejam obtidas em qualquer padrão de empreendimento. TUTIKIAN e HELENE [76] afirmam que um estudo de dosagem visa obter a mistura ideal e mais econômica, numa determinada região e com os materiais ali disponíveis, de forma que essa mistura atenda aos requisitos relacionados no projeto.

Em termos de dosagem de argamassas os procedimentos são os mais variados, não tendo uma definição quanto ao melhor modelo de dosagem, e havendo uma gama de publicações técnicas que abordam métodos de dosagem, desde formulações teóricas universais como os métodos do ACI (American Concrete Institute) e ABCP (Associação Brasileira de Cimento Portland), até procedimentos experimentais mais complexos como o método do empacotamento utilizados para o Concreto de Alto Desempenho (CAD).

Para uma execução mais precisa em campo o recomendado seria que fosse realizado todo o procedimento de dosagem em massa, contudo, essa condição se torna impraticável nos canteiros de obra brasileiros [77]. O processo empírico de dosagem, o não controle tecnológico de argamassas e a ausência de um procedimento de manutenção de argamassas de revestimento causa o aparecimento e proliferação de patologias [78].

De forma a verificar a correlação entre os atributos do banco de dados foi analisada a matriz de correlação (Figura 2) e o comportamento atributos preditivos em função da resistência à compressão (Figura 3). Observa-se que há uma forte correlação está entre as variáveis consumo de cimento (C_i) e resistência mecânica (Res) com o coeficiente de correlação de 0,61, podendo ser inferido que com o aumento do consumo de cimento há um acréscimo da resistência à compressão. É possível observar uma correlação moderada de 0,57 entre a água e o cimento, que são altamente correlacionadas visto que todo o processo de dosagem de argamassa tem como critério base a relação água/cimento. ZHANG *et al.* [79] em sua análise de dados observou uma correlação positiva fraca entre cimento e a água, superior a 0,20, podendo ser entendida em decorrência do conjunto de dados avaliados. Além disso, na Figura 3 é possível constatar esse comportamento de correlação positiva dos dados.

É possível verificar ainda a correlação moderada de 0,26 entre dias de cura e resistência. Como esperado, a resistência à compressão tende a aumentar com a quantidade de dias de cura, até a resistência de dosagem da mistura. CHEAH e RAMLI [25], APOLINÁRIO [28] e NING *et al.* [50] observaram em seus trabalhos um ganho de resistência de até 23% com idades superiores à 28 dias. A Figura 3 permite verificar esse comportamento de correlação positiva entre a cura e a resistência mecânica à compressão.

Ao se avaliar a correlação entre agregado natural e agregado artificial (RCD) é observada uma forte correlação negativa de -0,71, isso se dá porque o agregado artificial (RCD) é utilizado em substituição ao agregado natural, quanto maior a quantidade de um agregado menor será do outro.




Figura 2: Mapa de correlação da base de dados.

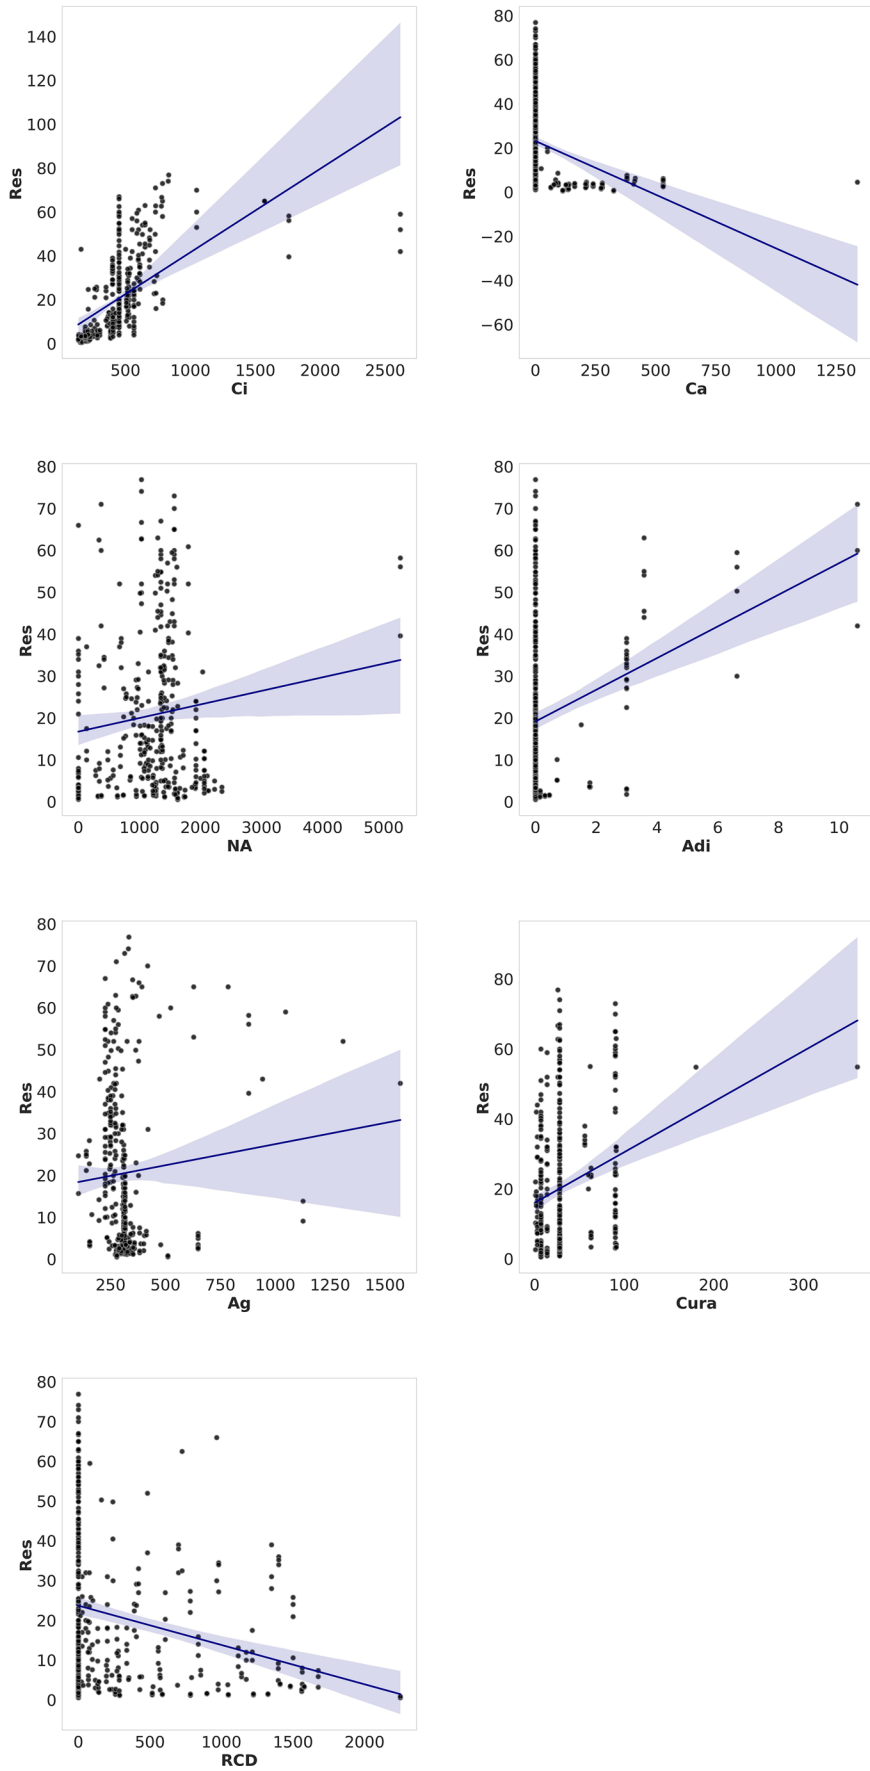


Figura 3: Gráfico de pontos com regressão linear para cada atributo do banco de dados em função da resistência mecânica da argamassa.

O estudo permitiu observar que os materiais, RCD e cal têm moderada correlação negativa de $-0,26$ e $-0,35$, respectivamente, com a resistência, logo quanto maior a quantidade desses materiais menor será a resistência da argamassa. Tal fato é condizente com os resultados de MORICONI [44], PIMENTEL *et al.* [35], MARVILLA *et al.* [40] e AGRAWAL *et al.* [43], onde os autores realizaram substituições em seus trabalhos e obtiveram a redução da resistência quando realizado o aumento da adição dos insumos anteriormente mencionados.

2.2. Modelos de aprendizado de máquina

Nesta seção são apresentados os modelos de aprendizado de máquina e a configuração utilizada para o emprego destes métodos. A linguagem de programação empregada na realização deste trabalho foi a linguagem Python e as bibliotecas que compõem esta linguagem como Pandas, Numpy, Scikit-Learn e Streamlit.

O primeiro grupo de técnicas empregadas foram as de regressão linear e polinomial. A regressão é uma técnica utilizada para se investigar a relação entre o espaço de entrada (variáveis independentes) e o espaço de saída (variável dependente). As regressões, segundo KANG *et al.* [80], são uma das técnicas mais comuns para realizar tarefas de predição. A regressão cria um sistema de variáveis de dependência (w) entre todos os parâmetros. Com isso esse método busca produzir uma função preditiva (\hat{y}) linear ou não linear que minimize a função de perda dada pela equação (1). Neste processo, y representa o vetor de observações e w o vetor de pesos que minimizam a função de perda. A função custo também é chamada de Erro Médio Quadrático (MSE) [81].

$$loss(x, w) = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i(x, w) - y_i)^2 \quad (1)$$

Para redução da possibilidade de um superajuste ao conjunto de dados é possível criar regras de regularização na função de perda. As técnicas mais comumente empregadas são Ridge (L2) e Lasso (L1) [82]. Neste trabalho foi empregada a técnica Ridge.

Os modelos de árvore de decisão foram introduzidos por BREIMAN *et al.* [83]. Em linhas gerais o procedimento das árvores de decisão divide os dados em hierarquias conforme a influência preditiva dos atributos. Segundo GÉRON [82], as árvores de decisão são constituídas de nós, que representam os atributos, e de ramos, provenientes desses nós e que recebem os valores possíveis para esses atributos (cada ramo descendente corresponde a um possível valor desse atributo). Nas árvores existem nós-folha (folha da árvore), que representam os diferentes valores de um conjunto de treinamento, ou seja, cada folha está associada a uma classe ou saída. Cada percurso na árvore (da raiz à folha) corresponde a uma regra de regressão, as Árvores de Decisão podem ser representadas como conjuntos de regras do tipo se-então. As regras são escritas considerando o trajeto do nó raiz até uma folha da árvore.

Da mesma forma que o processo de regressão minimiza os resíduos, a árvore buscará reduzir as impurezas em cada subconjunto formado. Para um problema de árvore de regressão a função custo é dada pela equação (2).

$$loss(Q_m, \theta) = \frac{n_m^l}{n_m} \cdot H(Q_m^l(\theta)) + \frac{n_m^d}{n_m} \cdot H(Q_m^d(\theta)), \quad \theta = (j, t_m) \quad (2)$$

$$H(Q_m, \theta) = \frac{1}{n_m} \cdot \sum_{y \in Q_m} (y - y_m^-)^2 \quad (3)$$

$$y_m^- = \frac{1}{n_m} \cdot \sum_{y \in Q_m} y \quad (4)$$

onde m representa o nó, j é o atributo, t_m representa o critério de decisão, $H(\)$ mede a impureza dos subconjuntos, n_m é o número de instâncias nos subconjuntos (n_m^l é o número de instâncias no subconjunto da esquerda e n_m^d é o número de instâncias no subconjunto da direita), Q_m é o subconjunto (Q_m^l representa o subconjunto esquerdo e Q_m^d representa o subconjunto da direita), y representa o valor observado no nó, e y_m^- representa o valor médio em cada região. As partições são fornecidas pelas Equações (5) e (6).

$$Q_m^l(\theta) = \{(x, y) \mid x_j \leq t_m\} \quad (5)$$

$$Q_m^d(\theta) = \{(x, y) \mid x_j > t_m\} \quad (6)$$

Logo, essas árvores conseguem realizar análises entre os dados e encontrar padrões que podem ser organizados em diferentes séries de regras de predição [80], tal modelo é usado usualmente como alternativa quando modelos lineares não são capazes de retornar uma acurácia dentro do nível aceitável [84].

Os métodos de aprendizado do tipo *ensemble* treinam combinações de modelos, que podem ser árvores de decisão, redes neurais, ou outros tradicionalmente usados no aprendizado supervisionado. Os métodos de *ensemble* ganharam popularidade porque muitos pesquisadores demonstraram seu desempenho de previsão superior em relação a modelos únicos em uma variedade de problemas [85].

No caso deste artigo será empregada a técnica de *Gradient Boosting* e de Floresta Aleatória. O *Gradient Boosting* possui a ideia geral de treinar sequencialmente o modelo preditivo (F), e a cada iteração corrigir seu modelo antecessor (F_{m-1}) [82]. A correção do modelo é dada em função da Equação (7) onde h_m representa o resultado do treinamento de uma árvore.

$$F_m(x) = F_{m-1}(x) + h_m(x) \tag{7}$$

Já o modelo de Floresta Aleatória foi proposto como um método de aprimoramento do algoritmo de árvore de decisão, onde se utiliza da técnica de ensacamento (*bootstrap aggregating* ou *bagging*) dos dados [86]. A técnica do *bagging* proposta por BREIMAN [87] gera um conjunto de dados por meio de amostragem de *bootstrap*, onde árvores são geradas por meio de uma seleção aleatória obtida em um conjunto de treinamento, com o intuito de reduzir os erros de previsão do algoritmo de aprendizado de máquina evitando o sobreajuste [88]. Cada árvore gerada aleatoriamente determina um resultado aleatório diferente com base no conjunto gerado, sendo calculada à média dos resultados, obtendo assim o valor predito pela floresta [89]. Um exemplo genérico de uma floresta aleatória é mostrado na Figura 4, onde os dados de entrada são aleatorizados para n árvores.

Por fim, as Redes Neurais Artificiais (RNA) fornecem uma abordagem robusta para aproximar funções alvo com valor real, valor discreto e valor vetorial. O estudo das RNAs foi inspirado em parte pela observação de que os sistemas biológicos de aprendizado são construídos por redes muito complexas de neurônios interconectados. Neste trabalho foram aplicadas as redes neurais artificiais multicamadas *Perceptron* (MLP – *Multilayer Perceptron*). A Figura 5 apresenta o modelo de uma MLP.

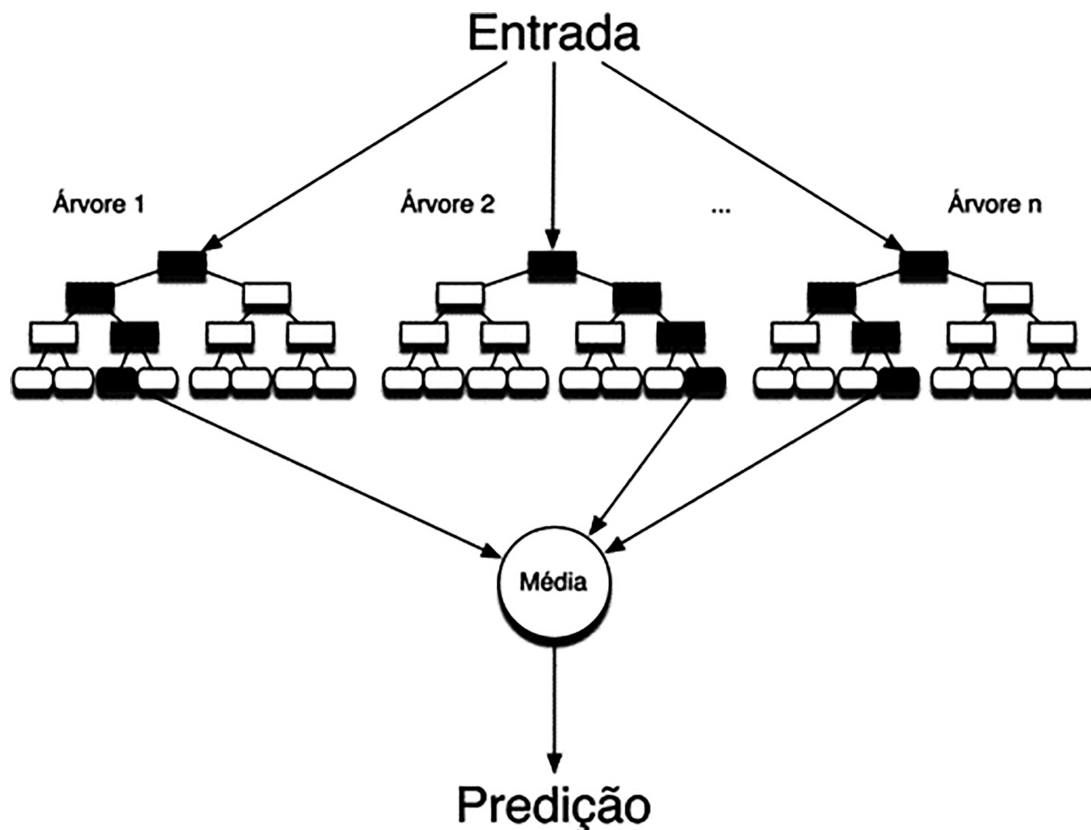


Figura 4: Esquema genérico do modelo de floresta aleatória [89].

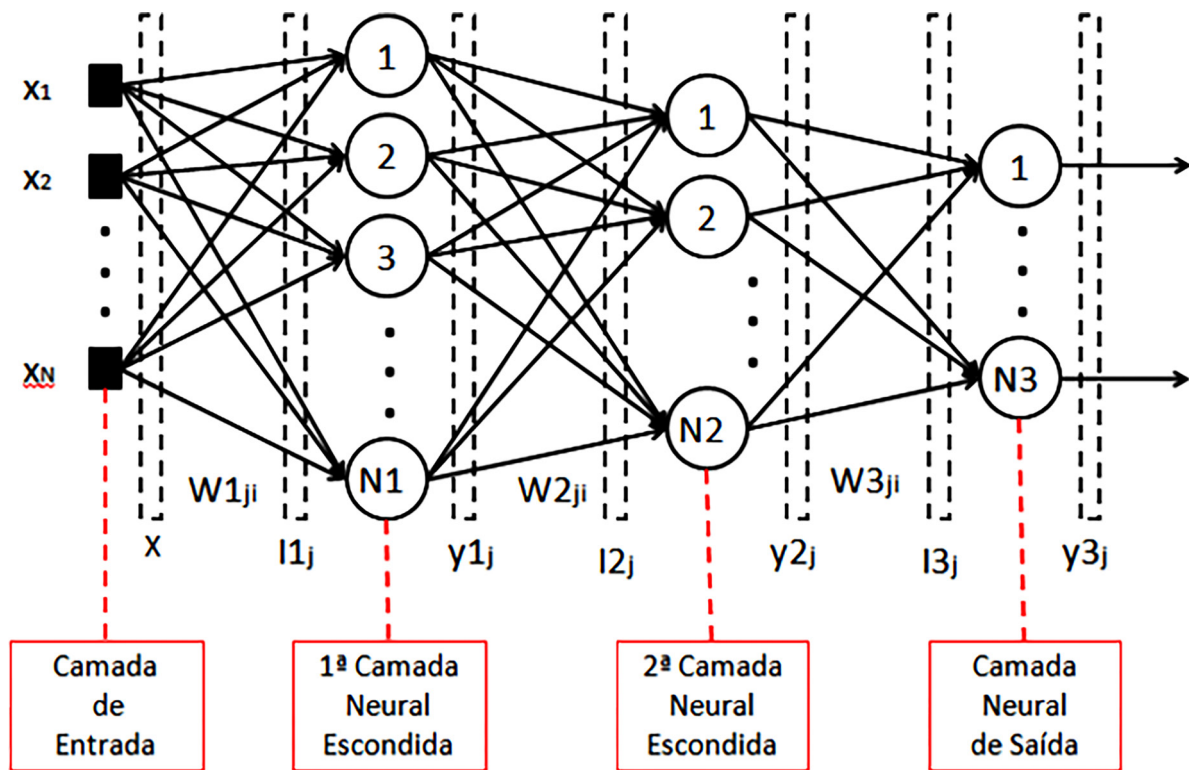


Figura 5: Esquema genérico do modelo de MLP [90].

Existem vários hiperparâmetros que precisam ser otimizados ao treinar um modelo de RNA porque eles controlam o processo de aprendizado e treinamento da rede. Eles incluem as escolhas do número de camadas ocultas usadas, o número de nós por camadas ocultas e o tipo de funções de ativação e as variáveis de treinamento. No caso de uma rede padrão o intuito do treinamento é a determinação dos pesos W_i de cada camada interna da rede. A camada de saída é a camada que possuirá uma função de ativação para converter o valor das camadas internas para uma saída \hat{y} padronizada.

A Tabela 3 apresenta os modelos computacionais empregados nesta pesquisa. No caso foram utilizados modelos de regressão, Árvores, *Ensembles* e Redes Neurais Artificiais multicamadas. As configurações empregadas foram as padronizadas dos modelos da biblioteca ScikitLearn do Python. Ademais as configurações que foram modificadas são apresentadas na Tabela 3.

É importante salientar que anteriormente à fase de treinamento foi empregado um modelo de validação do tipo *k-fold* com 10 camadas para verificar a estimativa de predição do modelo de Aprendizagem Máquina. Além disso, a separação do modelo para treinamento e teste foi 80% e 20%, sendo 80% dos dados para treino e 20% dos dados para teste.

Para avaliar a eficiência do método, foi empregada a medida de coeficiente de determinação R^2 . Normalmente, o R^2 é interpretado como representando a porcentagem de variação na variável dependente que é prevista a partir das variáveis independentes. A melhor pontuação possível é 1, e o R^2 pode ser negativo (porque o modelo pode ser arbitrariamente pior). O coeficiente de determinação fornece uma medida de quão bem os resultados observados são explicados pelo modelo, com base na proporção da variação total dos resultados explicada pelo modelo [91].

Após o treinamento e teste dos modelos, o resultado com melhor desempenho no parâmetro R^2 será submetido a uma tarefa de ajuste fino de parâmetros (em inglês *fine tuning*). Essa tarefa tem como objetivo otimizar o desempenho do modelo para o conjunto de dados informado melhorando sua capacidade de generalização. Para isso será utilizado os módulos da biblioteca Scikit-Learn, especificamente o módulo GridSearchCV que permite combinar diversos parâmetros de cada um dos modelos de IA verificando qual a configuração do algoritmo que resulta em um parâmetro R^2 superior.

Tabela 3: Modelos computacionais empregados.

MODELO	TIPO	DESCRIÇÃO E CONFIGURAÇÃO INICIAL
Regressão linear	Regressão	RL1 (linear)
Regressão polinomial		RP2 (2º grau)
Regressão Ridge		RR1 (linear)
Regressão Ridge polinomial		RR2 (2º grau)
Árvore de decisão	Árvore	AR2 (profundidade máxima = 2)
		AR5 (profundidade máxima = 5)
		AR10 (profundidade máxima = 10)
<i>Gradient Boosting</i>	<i>Ensemble</i>	GB2 (profundidade máxima = 2)
		GB5 (profundidade máxima = 5)
		GB10 (profundidade máxima = 10)
<i>Multilayer Perceptron</i>	Rede Neural	MLP64 × 64 (2 camadas 64 × 64)
		MLP128 × 64 × 32 (3 camadas 128 × 64 × 32)
		MLP128 × 128 × 64 (3 camadas 128 × 128 × 64)
Floresta Aleatória	<i>Ensemble</i>	RF2 (profundidade máxima = 2)
		RF5 (profundidade máxima = 5)
		RF10 (profundidade máxima = 10)

3. RESULTADOS

A Tabela 4 apresenta os resultados do treinamento e teste das técnicas de Aprendizado de Máquina empregadas neste artigo, mensurados através do coeficiente de determinação R^2 . CV(%) representa a média do coeficiente R^2 nas 10 partições de validação. TREINO (%) contém a média do coeficiente R^2 , dos 10 modelos obtidos durante a validação cruzada, aplicados sobre as respectivas partições de treino. TESTE (%) representa a média do coeficiente R^2 , dos 10 modelos obtidos durante a validação cruzada, aplicados sobre a partição de teste. É possível perceber que os dados possuem uma não linearidade, uma vez que as regressões lineares não conseguiram representar os dados de forma consistente. Para estes modelos, em particular, o valor do coeficiente R^2 foi inferior a 60%. Já as versões curvilíneas das regressões apresentaram R^2 superior, mostrando que parâmetros não lineares foram necessários para melhorar a precisão do modelo preditivo.

No caso deste trabalho todos os algoritmos foram treinados e também testados. Os modelos com R^2 superior a 85% no conjunto de teste foram AR5, AR10, GB2, GB5, GB10, RF5 e RF10 (tais modelos foram destacados na Tabela 4). Neste trabalho, o modelo com melhor precisão para os exemplos testados foi o ensemble GB10 e RF10, com precisão de cerca de 90% na fase de teste. Embora outros modelos como a rede neural com 3 camadas (MLP128 × 128 × 64) e a árvore de decisão (AR10) apresentem um R^2 de superior a 75%.

Nos resultados em geral (Tabela 4), pode ser notado que os valores da medida R^2 no treino são maiores do que os obtidos no teste. Este aspecto está relacionado ao amplamente conhecido problema, chamado de sobreajuste (em inglês *overfitting*), onde o modelo tem melhor desempenho com os dados de treinamento do que com dados novos do conjunto de teste.

A Figura 6 mostra uma comparação entre os valores previstos e os valores observados com base em modelos treinados e testados. É possível observar que a regressão linear de 1º grau (RL1 e RR1) possui os valores mais dispersos quando comparada ao modelo *Gradient Boosting*, que possui uma concentração de valores em torno da linha diagonal que corta o plano cartesiano, mostrando a eficiência deste último modelo na previsão da resistência à compressão. É possível observar também que há um melhor ajuste no gráfico para resistências menores.

Após o treinamento e teste do modelo de regressão, os dois modelos com maior grau de precisão foram submetidos a um ajuste fino de parâmetros. Para isso usou-se as ferramentas do Python de que permitiu elaborar a seguinte grade de parâmetros:

- atributo: “*n_estimators*” variando de 10 a 200;
- atributo: “*max_depth*” variando de 2 a 20;
- atributo: “*min_samples_split*” com os valores únicos 2, 5 e 10;
- atributo: “*min_samples_leaf*” com os valores únicos 1, 2 e 4;
- atributo: “*max_features*” com os valores únicos 1 e 2.

Vale salientar que os métodos *Gradient Boosting* e Floresta Aleatório compartilham parâmetros semelhantes, portanto o grupo de parâmetros é equivalente para os dois algoritmos em questão.

Com isso, foi possível obter novos valores de acurácia dos modelos na validação cruzada, sendo que os novos valores de R^2 são descritos na Tabela 5. Foi possível detectar uma melhora em torno de 7% nos modelos descritos, cujo o maior aumento foi de 7,84% no algoritmo de *Gradient Boosting*.

Tabela 4: Resultados da predição para os modelos computacionais empregados.

MODELO	DESCRIÇÃO	TREINO (%)	VALIDAÇÃO CRUZADA (%)	TESTE (%)
Regressão linear	RL1	58,46	41,31	48,93
Regressão polinomial	RL2	78,11	46,68	66,58
Regressão Ridge	RR1	58,45	41,71	49,09
Regressão Ridge polinomial	RR2	77,59	47,14	67,85
Árvore de decisão	AR2	62,42	52,72	51,68
	AR5	89,65	68,70	85,23
	AR10	98,68	72,40	87,59
<i>Gradient Boosting</i>	GB2	87,99	73,91	84,59
	GB5	98,56	81,01	92,49
	GB10	98,88	74,44	92,66
<i>Multilayer Perceptron</i>	MLP64 × 64	73,37	56,17	66,14
	MLP128 × 64 × 32	81,91	65,39	71,39
	MLP128 × 128 × 64	85,53	66,73	78,62
Floresta Aleatória	RF2	66,99	60,27	61,13
	RF5	91,43	76,77	85,97
	RF10	97,08	79,89	88,98

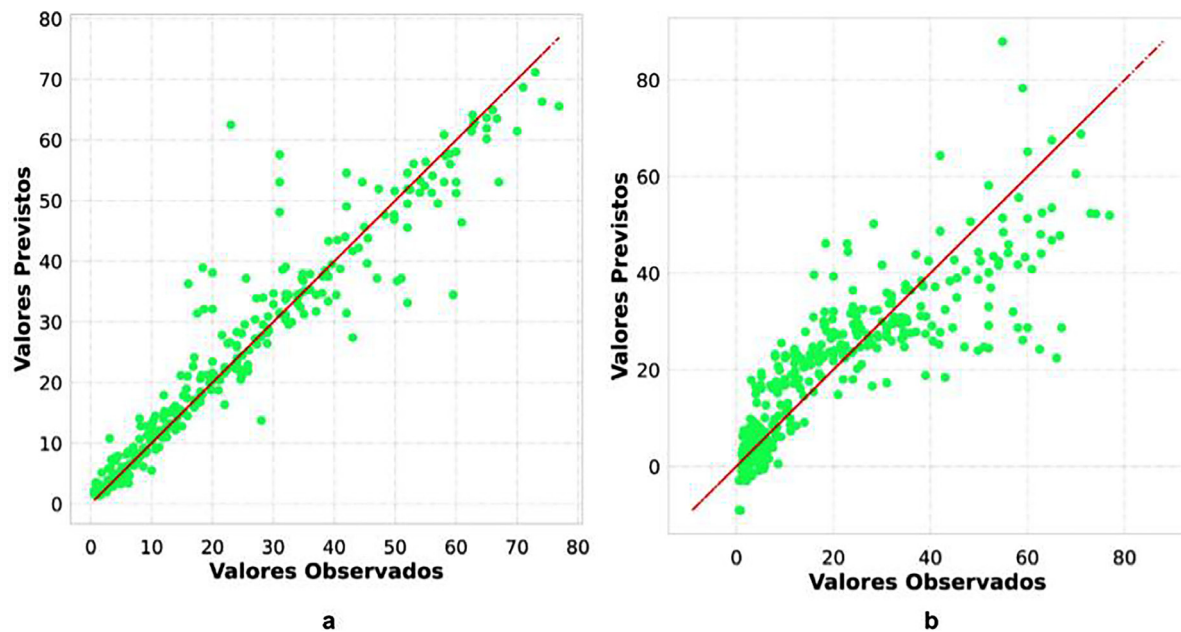


Figura 6: Comparação de dados previstos e observados para os modelos de *Gradient Boosting* e Regressão Linear. (a) *Gradient Boosting* $R^2 = 92,49$ no teste, (b) Regressão linear $R^2 = 58,42$ no teste.

Tabela 5: Atualização do modelo de aprendizado de máquina após o ajuste fino de parâmetros considerando um teste com validação cruzada.

MODELO	DESCRIÇÃO	R ² APÓS AJUSTE FINO (%)	MELHORA DO MODELO (%)	CONFIGURAÇÃO DO MODELO NO PYTHON
<i>Gradient Boosting</i>	GB5	88,85	7,84	Gradient Boosting Regressor (max_depth = 9, max_features = 2, min_samples_leaf = 2, min_samples_split = 10, n_estimators = 130)
Floresta Aleatória	RF10	85,64	7,19	Random Forest Regressor (max_depth = 18, max_features = 2, n_estimators = 160)

4. CONSIDERAÇÕES FINAIS

Com base na revisão bibliográfica, pode-se dizer que é possível aplicar o aprendizado de máquinas como ferramenta de predição da resistência de argamassas e implementá-la de maneira eficaz. Neste trabalho foram construídos modelos de AM para predição da resistência mecânica à compressão de argamassas, de diversos tipos, com adição ou não de resíduos. Os resultados obtidos foram coerentes com os resultados obtidos na literatura.

Em relação aos algoritmos utilizados, pode-se concluir que o aprendizado de máquinas é uma ferramenta potencial para problemas de predição de propriedades mecânicas em materiais, pois possibilita a determinação da propriedade de forma instantânea e com alto grau de precisão. Isso possibilita uma redução de custo e tempo de trabalho laboratorial para a determinação da resistência à compressão de argamassa, propriedade alvo desta pesquisa. Desse modo, pode-se concluir que os modelos aplicados neste trabalho, atingiram o objetivo do trabalho, tendo resultados satisfatórios. O modelo GB5 foi o melhor modelo de aprendizado de máquina encontrado no estudo e o mesmo foi selecionado para disponibilização *online* na plataforma CONCRETA (<https://wmpjrufg.github.io/Concreta/>).

O modelo de *Gradient Boosting* e Floresta Aleatória apresentaram acurácia superior a 80% e para potencializar a eficiência do algoritmo o mesmos foram submetidos a ajuste fino de parâmetros internos e então foi obtido um ganho de cerca de 7% no nível da acurácia do modelo. Tal ajuste fino foi aplicado antes do modelo ser colocado em produção na plataforma CONCRETA.

Apesar do banco de dados ser extenso no campo de estudo indicado, ressalva-se que é necessária uma atualização constante destes dados para que assim obtenha-se um modelo cada vez mais preciso. Além disso existe a questão do sobreajuste que pode ser detectado nos modelos treinados visto que existe uma queda percentual na acurácia do modelo quando comparada às fases de treino e teste. Aqui ressalta-se a importância da manutenção do banco de dados do modelo visto que com isso o algoritmo de aprendizado de máquina estará alinhado com as práticas atuais da indústria, resultando em predições mais precisas.

Na Tabela 4 foi detectada um certo sobreajuste dos dados. O problema de sobreajuste normalmente é relacionado ao fato de se ter um conjunto de dados de treino pequeno e modelos complexos, de forma que um modelo complexo consegue memorizar os dados de treinamento, porém, perde a capacidade de generalização. Mecanismos para tratar o sobreajuste de modelos, em vários casos, dependem da estrutura do modelo. Por exemplo, em modelos baseados em árvores, um dos mecanismos principais é a poda de árvore. Para redes neurais um dos principais mecanismos é a aplicação de *Dropout* para desconsiderar aleatoriamente pesos de algumas conexões durante o treinamento. Em determinadas circunstâncias, pode ser indicado o uso de técnicas de aumento de dados que independem do modelo.

Por fim, conclui-se que o aprendizado de máquina é uma ferramenta de cálculo prática na predição da resistência de argamassas, principalmente se aplicada durante o processo experimental, pois permite que apenas sejam realizados o processo de mistura para os traços com melhor característica de resistência, diminuindo ainda custos com a realização do rompimento dos corpos de prova, podendo ser realizado o processo de dosagem e obtenção da resistência apenas para os traços que forem mais interessantes, pois entende-se que a aprendizado de máquina é uma ferramenta que deve ser adotada em conjunto aos procedimentos normatizados.

Assim, em trabalhos futuros, podem ser consideradas as seguintes sugestões:

- Verificar a aplicabilidade do modelo para predição para outras propriedades mecânicas como resistência à tração e compressão na flexão;
- Realizar a dosagem experimental de novos traços no intervalo de consumo dessa pesquisa de forma a verificar o grau de precisão do modelo aqui apresentado;

- (c) Incorporação de novos tipos de resíduos nas misturas cimentícias;
- (d) Uso de modelos que permitem a redução do sobre ajuste como a técnica de *Dropout* em redes neurais artificiais.
- (e) Uso de outros modelos de aprendizado de máquina como por exemplo redes de aprendizado profundo que podem detectar propriedades mecânicas em função de visualização de imagens da argamassa utilizada;
- (f) Utilização de otimização inversa para predição de parâmetros no compósito dado um resultado experimental de compressão e/ou tração.

5. AGRADECIMENTOS

Agradecemos ao CNPQ pela concessão de bolsa através do projeto “Uso de técnicas de aprendizado de máquina para controle de qualidade de peças de concreto” processo 408343/2022-2.

6. BIBLIOGRAFIA

- [1] BEHERA, M., BHATTACHARYYA, S.K., MINOCHA, A.K., *et al.*, “Recycled aggregate from C&D waste & its use in concrete – A breakthrough towards sustainability in construction sector: a review”, *Construction & Building Materials*, v. 68, pp. 501–516, Out. 2014. doi: <http://doi.org/10.1016/j.conbuildmat.2014.07.003>.
- [2] PEREIRA JUNIOR, W.M., BORGES, R.A., ARAÚJO, D.L., *et al.*, “Parametric Identification and Sensitivity Analysis Combined with a Damage Model for Reinforced Concrete Structures”, *Arabian Journal for Science and Engineering*, v. 48, n. 4, pp. 4751–4767, Abr. 2023. doi: <http://doi.org/10.1007/s13369-022-07132-6>.
- [3] PEREIRA JUNIOR, W.M., BORGES, R.A., ARAÚJO, D.L., *et al.*, “A proposal to use the inverse problem for determining parameters in a constitutive model for concrete”, *Soft Computing*, v. 25, n. 13, pp. 8797–8815, Jul. 2021. doi: <http://doi.org/10.1007/s00500-021-05745-x>.
- [4] GAGG, C.R., “Cement and concrete as an engineering material: an historic appraisal and case study analysis”, *Engineering Failure Analysis*, v. 40, pp. 114–140, Maio. 2014. doi: <http://doi.org/10.1016/j.engfailanal.2014.02.004>.
- [5] PERUMAL, P., GOURIOU, C., ADESANYA, E., *et al.*, “Sustainable application of industrial side streams as alternative fine aggregates for cement mortar”, *Innovative Infrastructure Solutions*, v. 9, n. 1, pp. 29, Jan. 2024. doi: <http://doi.org/10.1007/s41062-023-01334-z>.
- [6] OLIVEIRA, S., SORANÇO, L., PEREIRA, T., *et al.*, “Estudo da adição de fibras de máscaras faciais N95, sílica ativa e pó de mármore em argamassa de alto desempenho”, *Matéria (Rio de Janeiro)*, v. 28, n. 2, pp. e20230042, 2023. doi: <http://doi.org/10.1590/1517-7076-rmat-2023-0042>.
- [7] CARVALHO, J.L.B.D., MARQUES, S.J.K., SOUZA, R.F.M.D., “Sustainable production of mortar with partial replacement of the fine aggregate by powdered carton packs”, *Matéria (Rio de Janeiro)*, v. 29, n. 2, pp. e20240111, 2024. doi: <http://doi.org/10.1590/1517-7076-rmat-2024-0111>.
- [8] SANTOS, E.A., ARAUJO, G.V.D.N., FONSÊCA, G.M., *et al.*, “Influência da incorporação de resíduo de lapidação de vidro nas propriedades da argamassa de cimento Portland”, *Matéria (Rio de Janeiro)*, v. 29, n. 2, pp. e20230330, 2024. doi: <http://doi.org/10.1590/1517-7076-rmat-2023-0330>.
- [9] CARASEK, H., ARAÚJO, R.C., CASCUDO, O., *et al.*, “Sand parameters influencing the consistency and bulk density of renderings mortars”, *Matéria (Rio de Janeiro)*, v. 21, n. 3, pp. 714–732, Set. 2016. doi: <http://doi.org/10.1590/S1517-707620160003.0068>.
- [10] ASSOCIAÇÃO BRASILEIRA DE RESÍDUOS E MEIO AMBIENTE, “Panorama 2022 – Abrelpe”, 2022. <https://www.abrema.org.br/panorama/>, acessado em agosto de 2024.
- [11] SOUSA, M.I.C., SANTANA, T.D.S., CORRÊA, C.A.R., *et al.*, “Avaliação da resistência à compressão, porosidade e espessura de micro fissura na zona de transição em argamassas com agregado miúdo reciclado”, *Matéria (Rio de Janeiro)*, v. 27, n. 2, pp. e13198, 2022. doi: <http://doi.org/10.1590/s1517-707620220002.1398>.
- [12] MARANGU, J.M., “Prediction of compressive strength of calcined clay based cement mortars using support vector machine and artificial neural network techniques”, *Journal of Sustainable Construction Materials and Technologies*, v. 5, n. 1, pp. 392–398, Abr. 2020. doi: <http://doi.org/10.29187/jscmt.2020.43>.
- [13] ASTERIS, P.G., KOOPALIPOOR, M., ARMAGHANI, D.J., *et al.*, “Prediction of cement-based mortars compressive strength using machine learning techniques”, *Neural Computing & Applications*, v. 33, n. 19, pp. 13089–13121, Out. 2021. doi: <http://doi.org/10.1007/s00521-021-06004-8>.

- [14] RAUECKER, J.C.N., PEREIRA JUNIOR, W.M., PITUBA, J.J.D.C., *et al.*, “Uma abordagem experimental e numérica para determinação de curvas de compressão para concreto simples e reforçados com fibras de aço”, *Matéria (Rio de Janeiro)*, v. 24, n. 3, pp. e12476, 2019. doi: <http://doi.org/10.1590/s1517-707620190003.0758>.
- [15] CHEN, Z., “Application of machine learning boosting and bagging methods to predict compressive and flexural strength of marble cement mortar”, *Materials Today. Communications*, v. 39, pp. 108600, Jun. 2024. doi: <http://doi.org/10.1016/j.mtcomm.2024.108600>.
- [16] ABIOYE, S.O., OYEDELE, L.O., AKANBI, L., *et al.*, “Artificial intelligence in the construction industry: a review of present status, opportunities and future challenges”, *Journal of Building Engineering*, v. 44, pp. 103299, Dez. 2021. doi: <http://doi.org/10.1016/j.jobeb.2021.103299>.
- [17] WANG, X.Q., CHEN, P., CHOW, C.L., *et al.*, “Artificial-intelligence-led revolution of construction materials: From molecules to Industry 4.0”, *Matter*, v. 6, n. 6, pp. 1831–1859, Jun. 2023. doi: <http://doi.org/10.1016/j.matt.2023.04.016>. PubMed PMID: 37304344.
- [18] MAHDINIA, S., ESKANDARI-NADDAF, H., SHADNIA, R., “Effect of cement strength class on the prediction of compressive strength of cement mortar using GEP method”, *Construction & Building Materials*, v. 198, pp. 27–41, Fev. 2019. doi: <http://doi.org/10.1016/j.conbuildmat.2018.11.265>.
- [19] CRUVINEL, L.E.A., PEREIRA, W.M., DE CAMPOS, A.I., *et al.*, “Application of artificial intelligence models to predict the compressive strength of concrete”, *Advances in Computational Intelligence*, v. 4, n. 2, pp. 4, Jun. 2024. doi: <http://doi.org/10.1007/s43674-024-00072-8>.
- [20] SILVA NETO, A.P.A., BRITES, B.G., SANTOS, L.L., “*Substituição do agregado miúdo por resíduo proveniente do beneficiamento do mármore e granito (rbmg) em argamassa*”, Bacharelado, Uniderp, Campo Grande, 2016.
- [21] SILVA, I.A.C., “*Adição de fibras de papel kraft e gesso reciclado em argamassas de assentamento*”, Bacharelado, Universidade Federal de Goiás, Catalão, 2019.
- [22] LARA, G.T.D., SALVADOR, C.M., GARCIA, R.S., “Análise comparativa de resistência à compressão entre argamassas de revestimento à base de cal hidratada e aditivo plastificante líquido”, *Revista Funec Científica Multidisciplinar*, v. 6, n. 8, pp. 180–197, 2017.
- [23] ARAÚJO, N.N., “*Desempenho de argamassas de revestimentos produzidas com agregados reciclados oriundos do resíduo de construção e demolição da Grande Natal-RN*”, Tese de M.Sc., UFRN, Natal, 2014.
- [24] TOKARSKI, R.B., MATOSKI, A., CECHIN, L., *et al.*, “Comportamento das argamassas de revestimento no estado fresco, compostas com areia de britagem de rocha calcária e areia natural”, *Matéria (Rio de Janeiro)*, v. 23, n. 3, pp. e12196, Out. 2018. doi: <http://doi.org/10.1590/s1517-707620180003.0530>.
- [25] CHEAH, C.B., RAMLI, M., “Mechanical strength, durability and drying shrinkage of structural mortar containing HCWA as partial replacement of cement”, *Construction & Building Materials*, v. 30, pp. 320–329, Maio. 2012. doi: <http://doi.org/10.1016/j.conbuildmat.2011.12.009>.
- [26] LEE, T., RAO, M.-K., “Recycling municipal incinerator fly- and scrubber-ash into fused slag for the substantial replacement of cement in cement-mortars”, *Waste Management (New York, N.Y.)*, v. 29, n. 6, pp. 1952–1959, Jun. 2009. doi: <http://doi.org/10.1016/j.wasman.2009.01.002>. PubMed PMID: 19216067.
- [27] PALOD, R., DEO, S.V., RAMTEKKAR, G.D., “Utilization of waste from steel and iron industry as replacement of cement in mortars”, *Journal of Material Cycles and Waste Management*, v. 21, n. 6, pp. 1361–1375, Nov. 2019. doi: <http://doi.org/10.1007/s10163-019-00889-3>.
- [28] APOLINÁRIO, E.C.A., “*Influência da adição do resíduo proveniente do corte de mármore e granito (rcmg) nas propriedades de argamassas de cimento portland*”, Tese de M.Sc., UFBA, Salvador, 2014.
- [29] SILVA, A.R., CABRAL, C., PINTO, E.N.M.G., “Substituição parcial do cimento portland por resíduo de cerâmica vermelha em argamassas: estudo da atividade pozolânica”, In: *XXII Congresso Brasileiro de Engenharia e Ciência dos Materiais – CBECiMat*, Natal, 2016.
- [30] MOURA, A.A., “*Argamassa com substituição parcial do cimento por resíduos industriais*”, M.Sc. Thesis, Universidade Tecnológica Federal do Paraná, Curitiba, 2018.
- [31] FORMIGONI, M.W., PAVEI, E.G., “*Análise da influência da substituição parcial do cimento portland por resíduos de placas cerâmicas desconformes na argamassa*”, Trabalho de Conclusão de Curso, Unesc, Criciúma, 2016.

- [32] TRENTIN, P.O., MANICA, J., VANZETTO, S.C., *et al.*, “Substituição parcial de agregado miúdo por resíduo de vidro moído na produção de argamassa”, *Matéria (Rio de Janeiro)*, v. 25, n. 1, pp. e–12576, 2020. doi: <http://doi.org/10.1590/s1517-707620200001.0903>.
- [33] GUERRA, T.D., LUZ, P.M.S.G., “Argamassas manufaturadas com substituição parcial do cimento por pet triturado”, In: *Congresso Nacional de Pesquisa e Ensino de Ciências*, p. 1–9, 2018.
- [34] RIBEIRO, K.B. “Influência da substituição de cimento por pentóxido de nióbio na resistência à compressão de argamassas”, In: *Relatório de Iniciação Científica*, Brasília, UniCEUB, 2019.
- [35] PIMENTEL, L.L., PISSOLATO JUNIOR, O., JACINTHO, A.E.P.G.D.A., *et al.*, “Argamassa com areia proveniente da britagem de resíduo de construção civil – Avaliação de características físicas e mecânicas”, *Matéria (Rio de Janeiro)*, v. 23, n. 1, pp. e11969, Mar. 2018. doi: <http://doi.org/10.1590/s1517-707620170001.0305>.
- [36] PCZIECZEK, A., EFFTING, C., GOMES, I.R., *et al.*, “Statistical analysis of mechanical properties of mortars with fly ash and waste tire rubber”, *Revista IBRACON de Estruturas e Materiais*, v. 12, n. 4, pp. 790–811, Ago. 2019. doi: <http://doi.org/10.1590/s1983-41952019000400005>.
- [37] MAZURANA, L., POSSAN, E., “Carbonation and CO₂ uptake in rendering mortars produced with recycled construction and demolition waste”, In: *Memorias CONPAT 2019*, 2019.
- [38] SANTOS, R.A.D., LIRA, B.B., RIBEIRO, A.C.M., “Argamassa com substituição de agregado natural por resíduo de britagem de granito”, *Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental*, v. 8, n. 8, pp. 1818–1828, Jan. 2013.
- [39] BONFIM, W.B., CARVALHO, I.M., DE PAULA, H.M., “Uso de lama residual de concreto como substituto da cal hidratada para produção de argamassas de revestimento”, *Revista Eletrônica de Engenharia Civil*, v. 15, n. 2, pp. 75–87, Sep. 2019.
- [40] MARVILA, M., AZEVEDO, A., ZANELATO, E., *et al.*, “Interference of the water / cement ratio in the technological properties of mortars in the hardened state”, In: *63 Congresso Brasileiro de Cerâmica*, Bonito, 2019.
- [41] FERRARI, J.R., SILVA, R.V.D., LOUZADA, D.M., *et al.*, “Reuse of printed circuit boards substrate in the production of mortars”, *Tecnologica em Metalurgia, Materiais e Mineração*, v. 19, pp. e2656, 2022. doi: <http://doi.org/10.4322/2176-1523.20222656>.
- [42] KURZ, M.N., BRANDELLI, T.M., PALIGA, C.M., *et al.*, “A potencialidade do uso de resíduo de borracha de pneu em argamassa: análise das propriedades físicas e mecânicas”, *Matéria (Rio de Janeiro)*, v. 23, n. 3, pp. e12154, Out. 2018. doi: <http://doi.org/10.1590/s1517-707620180003.0488>.
- [43] AGRAWAL, Y., SIDDIQUE, S., SHARMA, R.K., *et al.*, “Valorization of granite production dust in development of rich and lean cement mortar”, *Journal of Material Cycles and Waste Management*, v. 23, n. 2, pp. 686–698, Mar. 2021. doi: <http://doi.org/10.1007/s10163-020-01158-4>.
- [44] MORICONI, G., “Environmentally-friendly mortars: a way to improve bond between mortar and brick”, *Materials and Structures*, v. 36, n. 264, pp. 702–708, Out. 2003. doi: <http://doi.org/10.1617/13872>.
- [45] MOHAMMADHOSSEINI, H., LIM, N.H.A.S., TAHIR, M., *et al.*, “Performance evaluation of green mortar comprising ceramic waste as cement and fine aggregates replacement”, *SN Applied Sciences*, v. 1, n. 6, pp. 557, Jun. 2019.
- [46] AMIN, S.K., ALLAM, M.E., GARAS, G.L., *et al.*, “A study of the chemical effect of marble and granite slurry on green mortar compressive strength”, *Bulletin of the National Research Center*, v. 44, n. 1, pp. 19, Dez. 2020. doi: <http://doi.org/10.1186/s42269-020-0274-8>.
- [47] RAMJAN, S., TANGCHIRAPAT, W., JATURAPITAKKUL, C., “Effects of binary and ternary blended cements made from palm oil fuel ash and rice husk ash on alkali-silica reaction of mortar”, *Arabian Journal for Science and Engineering*, v. 43, n. 4, pp. 1941–1954, Abr. 2018. doi: <http://doi.org/10.1007/s13369-017-2843-1>.
- [48] SINGH, L.P., GOEL, A., BHATTACHHARYYA, S.K., *et al.*, “Effect of morphology and dispersibility of silica nanoparticles on the mechanical behaviour of cement mortar”, *International Journal of Concrete Structures and Materials*, v. 9, n. 2, pp. 207–217, Jun. 2015. doi: <http://doi.org/10.1007/s40069-015-0099-2>.
- [49] BU, J., TIAN, Z., ZHENG, S., *et al.*, “Effect of sand content on strength and pore structure of cement mortar”, *Journal of Wuhan University of Technology-Material Science and Education*, v. 32, n. 2, pp. 382–390, Apr. 2017.

- [50] NING, B., XU, J., CHEN, S., “Mechanical properties and solidified mechanism of tailings mortar with waste glass”, *Journal of Wuhan University of Technology-Material Science and Education*, v. 30, n. 6, pp. 1240–1246, Dec. 2015.
- [51] MAHIR MAHMUD, H., FARAH NORA AZNIETA, A.A., GATEA, S.J., “Evaluation of rubberized fibre mortar exposed to elevated temperature using destructive and non-destructive testing”, *KSCE Journal of Civil Engineering*, v. 21, n. 4, pp. 1347–1358, Maio. 2017. doi: <http://doi.org/10.1007/s12205-016-0721-0>.
- [52] AADI, A.S., MOHAMMED ALI, T.K., ALI, R.A.A., *et al.*, “The mechanical properties of green mortar contained aluminum wastes as substitution of sand”, *Materials Today: Proceedings*, v. 42, pp. 3002–3009, 2021. doi: <http://doi.org/10.1016/j.matpr.2020.12.812>.
- [53] LI, L.G., LIN, Z.H., CHEN, G.M., *et al.*, “Reutilizing clay brick dust as paste substitution to produce environment-friendly durable mortar”, *Journal of Cleaner Production*, v. 274, pp. 122787, Nov. 2020. doi: <http://doi.org/10.1016/j.jclepro.2020.122787>.
- [54] LI, L.G., ZHUO, Z.Y., ZHU, J., *et al.*, “Adding ceramic polishing waste as paste substitute to improve sulphate and shrinkage resistances of mortar”, *Powder Technology*, v. 362, pp. 149–156, Fev. 2020. doi: <http://doi.org/10.1016/j.powtec.2019.11.117>.
- [55] PATEL, D., SHRIVASTAVA, R., TIWARI, R.P., *et al.*, “Properties of cement mortar in substitution with waste fine glass powder and environmental impact study”, *Journal of Building Engineering*, v. 27, pp. 100940, Jan. 2020. doi: <http://doi.org/10.1016/j.jobe.2019.100940>.
- [56] ZHAO, Z., BENZERZOUR, M., ABRIAK, N.-E., *et al.*, “Use of uncontaminated marine sediments in mortar and concrete by partial substitution of cement”, *Cement and Concrete Composites*, v. 93, pp. 155–162, Out. 2018. doi: <http://doi.org/10.1016/j.cemconcomp.2018.07.010>.
- [57] DEMIR, İ., GÜZELKÜCÜK, S., SEVİM, Ö., “Effects of sulfate on cement mortar with hybrid pozzolan substitution”, *Engineering Science and Technology an International Journal*, v. 21, n. 3, pp. 275–283, Jun. 2018.
- [58] NASR, M.S., ALI, I.M., HUSSEIN, A.M., *et al.*, “Utilization of locally produced waste in the production of sustainable mortar”, *Case Studies in Construction Materials*, v. 13, pp. e00464, Dez. 2020. doi: <http://doi.org/10.1016/j.cscm.2020.e00464>.
- [59] RAINI, I., JABRANE, R., MESRAR, L., *et al.*, “Evaluation of mortar properties by combining concrete and brick wastes as fine aggregate”, *Case Studies in Construction Materials*, v. 13, pp. e00434, Dez. 2020. doi: <http://doi.org/10.1016/j.cscm.2020.e00434>.
- [60] JUSTO-REINOSO, I., SRUBAR III, W.V., CAICEDO-RAMIREZ, A., *et al.*, “Fine aggregate substitution by granular activated carbon can improve physical and mechanical properties of cement mortars”, *Construction & Building Materials*, v. 164, pp. 750–759, Mar. 2018. doi: <http://doi.org/10.1016/j.conbuildmat.2017.12.181>.
- [61] AZEVEDO, A.R.G., CECCHIN, D., CARMO, D.F., *et al.*, “Analysis of the compactness and properties of the hardened state of mortars with recycling of construction and demolition waste (CDW)”, *Journal of Materials Research and Technology*, v. 9, n. 3, pp. 5942–5952, Maio. 2020. doi: <http://doi.org/10.1016/j.jmrt.2020.03.122>.
- [62] ABADOU, Y., GHRIEB, A., BUSTAMANTE, R., “Crushed concrete waste influence on dune sand mortar performance. Contribution to the valorization”, *Materials Today: Proceedings*, v. 33, pp. 1758–1761, 2020. doi: <http://doi.org/10.1016/j.matpr.2020.04.871>.
- [63] KABEER, K.I.S.A., VYAS, A.K., “Experimental investigation on utilization of dried marble slurry as fine aggregate in lean masonry mortars”, *Journal of Building Engineering*, v. 23, pp. 185–192, Maio 2019. doi: <http://doi.org/10.1016/j.jobe.2019.01.034>.
- [64] SELVARANJAN, K., NAVARATNAM, S., GAMAGE, J.C.P.H., *et al.*, “Thermal and environmental impact analysis of rice husk ash-based mortar as insulating wall plaster”, *Construction & Building Materials*, v. 283, pp. 122744, Maio. 2021. doi: <http://doi.org/10.1016/j.conbuildmat.2021.122744>.
- [65] CHAHOUR, K., SAFI, B., “Mechanical behavior and chemical durability of marble-based mortar: application to panels subjected to punching”, *Construction & Building Materials*, v. 232, pp. 117245, Jan. 2020. doi: <http://doi.org/10.1016/j.conbuildmat.2019.117245>.
- [66] SINGH CHOUHAN, H., SINGH CHOUHAN, R., KALLA, P., *et al.*, “Effect of Kota stone slurry on strength properties of cement mortar mixes”, *Materials Today: Proceedings*, v. 44, pp. 4557–4562, 2021. doi: <http://doi.org/10.1016/j.matpr.2020.10.814>.

- [67] SAFI, B., SAIDI, M., DAOUI, A., *et al.*, “The use of seashells as a fine aggregate (by sand substitution) in self-compacting mortar (SCM)”, *Construction & Building Materials*, v. 78, pp. 430–438, Mar. 2015. doi: <http://doi.org/10.1016/j.conbuildmat.2015.01.009>.
- [68] KABAY, N., MIYAN, N., ÖZKAN, H., “Utilization of pumice powder and glass microspheres in cement mortar using paste replacement methodology”, *Construction & Building Materials*, v. 282, pp. 122691, Maio. 2021. doi: <http://doi.org/10.1016/j.conbuildmat.2021.122691>.
- [69] YUN, C.M., RAHMAN, M.R., PHING, C.Y.W., *et al.*, “The curing times effect on the strength of ground granulated blast furnace slag (GGBFS) mortar”, *Construction & Building Materials*, v. 260, pp. 120622, Nov. 2020. doi: <http://doi.org/10.1016/j.conbuildmat.2020.120622>.
- [70] CHEBOUB, T., SENHADJI, Y., KHELAFI, H., *et al.*, “Investigation of the engineering properties of environmentally-friendly self-compacting lightweight mortar containing olive kernel shells as aggregate”, *Journal of Cleaner Production*, v. 249, pp. 119406, Mar. 2020. doi: <http://doi.org/10.1016/j.jclepro.2019.119406>.
- [71] HUANG, Q., ZHU, X., XIONG, G., *et al.*, “Recycling of crushed waste clay brick as aggregates in cement mortars: an approach from macro- and micro-scale investigation”, *Construction & Building Materials*, v. 274, pp. 122068, Mar. 2021. doi: <http://doi.org/10.1016/j.conbuildmat.2020.122068>.
- [72] FERREIRA, R.L., ANJOS, M.A., MAIA, C., *et al.*, “Long-term analysis of the physical properties of the mixed recycled aggregate and their effect on the properties of mortars”, *Construction & Building Materials*, v. 274, pp. 121796, 2021.
- [73] CARASEK, H., *Argamassas*, São Paulo, Ibracon, 2017.
- [74] RECENA, F.A.P., *Conhecendo Argamassa*, Porto Alegre, EdiPUCRS, 2023.
- [75] SABBATINI, F.H., *Argamassas de assentamento para paredes de alvenaria resistente*, São Paulo, ABCP, 1998.
- [76] TUTIKIAN, B.F., HELENE, P., “Dosagem dos concretos de cimento Portland”, *Concreto: Ciência e Tecnologia*, v. 1, pp. 38, 2011.
- [77] AMBROZEWICZ, P.H.L., *Materiais de construção: normas, especificações, aplicação e ensaios de laboratório*, São Paulo, Pini, 2012.
- [78] GOMES, A.O., NEVES, C.M.M., “Proposta de método de dosagem racional de argamassas contendo argilominerais”, *Ambiente Construído*, v. 2, pp. 19–30, 2008.
- [79] ZHANG, J., HUANG, Y., MA, G., *et al.*, “Mixture optimization for environmental, economical and mechanical objectives in silica fume concrete: a novel frame-work based on machine learning and a new meta-heuristic algorithm”, *Resources, Conservation and Recycling*, v. 167, pp. 105395, Abr. 2021. doi: <http://doi.org/10.1016/j.resconrec.2021.105395>.
- [80] KANG, M.-C., YOO, D.-Y., GUPTA, R., “Machine learning-based prediction for compressive and flexural strengths of steel fiber-reinforced concrete”, *Construction & Building Materials*, v. 266, pp. 121117, Jan. 2021. doi: <http://doi.org/10.1016/j.conbuildmat.2020.121117>.
- [81] RUSSELL, S.J., NORVIG, P., *Artificial intelligence: a modern approach*, 3rd ed., Harlow, Pearson, 2016.
- [82] GÉRON, A., *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*, 2nd ed., Sebastopol, O’Reilly Media, 2019.
- [83] BREIMAN, L., FRIEDMAN, J.H., OLSHEN, R.A., *et al.*, *Classification and Regression Trees*, Wadsworth, Routledge, 1984.
- [84] GÜÇLÜER, K., ÖZBEYAZ, A., GÖYMEN, S., *et al.*, “A comparative investigation using machine learning methods for concrete compressive strength estimation”, *Materials Today. Communications*, v. 27, pp. 102278, Jun. 2021. doi: <http://doi.org/10.1016/j.mtcomm.2021.102278>.
- [85] OZA, N.C., “Online Ensemble Learning”, In: *Proceedings of the Seventeenth National Conference on Artificial Intelligence and Twelfth Conference on Innovative Applications of Artificial Intelligence*, Austin, Texas, USA, p. 1109, 2000.
- [86] ARCHER, K.J., KIMES, R.V., “Empirical characterization of random forest variable importance measures”, *Computational Statistics & Data Analysis*, v. 52, n. 4, pp. 2249–2260, Jan. 2008. doi: <http://doi.org/10.1016/j.csda.2007.08.015>.
- [87] BREIMAN, L., “Bagging predictors”, *Machine Learning*, v. 24, n. 2, pp. 123–140, Ago. 1996. doi: <http://doi.org/10.1007/BF00058655>.

- [88] SANTANA, F.B., “*Floresta aleatória para desenvolvimento de modelos multivariados de classificação e regressão em química analítica*”, Tese de D.Sc., Universidade de Campinas, Campinas, 2020.
- [89] MONTAÑO, R.A.N.R., “*Aplicação de técnicas de aprendizado de máquina na mensuração florestal*”, Tese de D.Sc., Universidade Federal do Paraná, Curitiba, 2016.
- [90] AGUIAR, F.G., “*Utilização de redes neurais artificiais para detecção de padrões de vazamentos em dutos*”, Tese de M.Sc., Universidade de São Paulo, São Carlos, 2010.
- [91] SAPRA, R.L., “Using R2 with caution”, *Current Medicine Research and Practice*, v. 4, n. 3, pp. 130–134, Maio. 2014. doi: <http://doi.org/10.1016/j.cmrp.2014.06.002>.