



UNIVERSIDADE FEDERAL DO CEARÁ - CAMPUS RUSSAS
CURSO DE ENGENHARIA CIVIL

DIANA IRENE BARBOSA MURO

**AVALIAÇÃO DE MODELOS DE APRENDIZADO DE MÁQUINA PARA
ESTIMATIVAS DA RESISTÊNCIA EM CONCRETO AUTOADENSÁVEIS**

RUSSAS

2022

DIANA IRENE BARBOSA MURO

AVALIAÇÃO DE MODELOS DE APRENDIZADO DE MÁQUINA PARA
ESTIMATIVAS DA RESISTÊNCIA EM CONCRETO AUTOADENSÁVEIS

Trabalho de Conclusão do Curso, apresentado à
Universidade Federal do Ceará, como requisito à
obtenção do título de Bacharel em Engenharia
Civil.

Orientador: Prof. Dr. Esequiel Fernandes Teixeira
Mesquita.

RUSSAS

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- M958a Muro, Diana Irene Barbosa.
Avaliação de Modelos de Aprendizado de Máquina para Estimativas da Resistência em Concreto Autoadensáveis / Diana Irene Barbosa Muro. – 2022.
50 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Russas, Curso de Curso de Engenharia Civil, Russas, 2022.
Orientação: Prof. Dr. Esequiel Fernandes Teixeira Mesquita.
1. Aprendizado de Máquina. 2. Concreto Autoadensável. 3. Dosagem. I. Título.

CDD 620

DIANA IRENE BARBOSA MURO

AVALIAÇÃO DE MODELOS DE APRENDIZADO DE MÁQUINA PARA
ESTIMATIVAS DA RESISTÊNCIA EM CONCRETO AUTOADENSÁVEIS

Trabalho de Conclusão do Curso, apresentado à
Universidade Federal do Ceará, como requisito à
obtenção do título de Bacharel em Engenharia
Civil.

Orientador: Prof. Dr. Esequiel Fernandes Teixeira
Mesquita.

Aprovada em: ___/___/___

BANCA EXAMINADORA

Prof. Dr. Esequiel Fernandes Teixeira Mesquita (Orientador)
Universidade Federal do Ceará (UFC)

Profa. Ms. Andriele Nascimento de Souza
Universidade Federal do Ceará (UFC)

Profa. Dra. Rosineide Fernando da Paz
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

A Deus, por me ajudar todos os dias a trilhar a jornada em busca de ser uma pessoa melhor e querer sempre progredir profissionalmente, por me dar coragem e perseverança.

Aos meus pais, em especial minha mãe, Anália Iraneide, e aos meus irmãos Débora Flávia e Daniel Francisco, por sempre me incentivarem a seguir meus objetivos, dar o exemplo de perseverança, e por todo apoio.

A minha segunda família, Daniel Lira, pelo seu companheirismo, cuidado e ensinamentos, me guiando na vida acadêmica e profissional. À Dona Lúcia, por me adotar como família mesmo em tempos difíceis ao final da graduação, dando todo o apoio.

Ao professor Otávio Rangel, que mesmo com todas as dificuldades de uma pandemia, seguiu dando as orientações e motivações para a entrega do trabalho de finalização do curso.

Ao professor Esequiel Mesquita por acompanhar o desenvolvimento deste trabalho, com as orientações e correções para a entrega deste trabalho.

Aos alunos do PEC e ao Grupo de Pesquisa em Reologia de Materiais (REOM), da Universidade Federal do Ceará, que permitiram que esse trabalho fosse desenvolvido, e contribuições.

Ao professor Lucas Babadopolus, pela oportunidade de participar do desenvolvimento da pesquisa que gerou este trabalho.

Aos professores membros da banca, pelo tempo concedido e contribuições para o aperfeiçoamento deste trabalho.

A todos vocês, meu muito obrigada.

RESUMO

A validação do processo de dosagem de concretos depende também de ensaios laboratoriais que confirmem as características e resistências estimadas inicialmente. Por se tratar de um método experimental, esse processo tende a ser oneroso e laborioso, com possíveis ajustes por tentativa e erro. Dessa forma, pesquisas atuais apontam aplicações de tecnologias que otimizem esse processo, utilizando tecnologias como aprendizado de máquina, com potencial de reduzir e otimizar o fluxo de trabalho acima. Nesse contexto, buscou-se avaliar a performance de diferentes modelos de aprendizado para estimativas e previsão da resistência à compressão de concretos autoadensáveis, investigando a influência de materiais básicos (cimento, agregados, água) como aditivos e adições (plastificantes, pozolanas). Para isso, foi elaborado um banco de dados com 503 dosagens de concreto autoadensável, retirados da literatura, sendo implementado modelos de Regressão Linear, Lasso, e de Ridge, e regressores de Árvore de Decisões e de Floresta Aleatória, além de modelos mais simplificados de rede neural, como Regressor MLP e Regressor Polinomial, sendo esses modelos os mais abordados em literatura para problemas dessa natureza. Previamente à implementação, foi realizada uma análise exploratória de dados (AED), onde pôde ser gerado um mapa de correlações para balizamento da avaliação dos modelos gerados. Foi possível verificar, não somente correlações entre os componentes do concreto autoadensável, mas outros fatores como a precisão, desvio padrão e gasto computacional de cada modelo implementado.

Palavras-chave: Aprendizado de Máquina; Concreto Autoadensável; Dosagem.

ABSTRACT

The process of validation of the concrete dosage also depends on laboratorial tests that confirm the characteristics and strengths initially estimated. As it is an experimental method, this process tends to be onerous and laborious, with possible adjustments by trial and error. Thus, recent researches show applications of technologies that optimize this process, using technologies such as machine learning, with the potential to reduce and optimize the workflow. In this context, this paper evaluated the performance of different learning models for estimating and predicting the compressive strength of self-compacting concrete, investigating the influence of basic materials (cement, aggregates, water) as additives and additions (plasticizers, pozzolans). For this, a database was created with 503 dosages of self-compacting concrete, taken from the literature, with Linear, Lasso, and Ridge Regression models being implemented, and Decision Tree and Random Forest regressors, in addition to more simplified models of neural network, as MLP Regressor and Polynomial Regressor, being these models the most referred in the literature for problems of this nature. Prior to implementation, an exploratory data analysis (AED) was performed, where a correlation map could be generated to guide the evaluation of the generated models. It was possible to verify not only correlations between the components of the self-compacting concrete, but other factors such as precision, standard deviation and computational expense of each implemented model.

Key-words: Machine Learning; Self-compact concrete; Dosage.

LISTA DE FIGURAS

Figura 1 - Fluxograma da Metodologia empregada no trabalho.	12
Figura 2 - Listagem das bibliotecas utilizadas, para os processamentos e análises iniciais....	18
Figura 3 - Heatmap de correlação entre atributos de materiais básicos e variável resultado..	19
Figura 4 - Heatmap de correlação entre atributos de aditivos, adições e variável resultado...21	
Figura 5 - Pairplot de correlação entre materiais básicos e variável resultado.	23
Figura 6 - Pairplot de correlação entre atributos de aditivos, adições e variável resultado. ...	24
Figura 7 - Relação entre consumo de cimento, água, superplastificante e resistência à compressão do concreto autoadensável.	26
Figura 8 - Curva e histograma das resistências à compressão observadas.....	27
Figura 9 - Disposição dos coeficientes determinados para as regressões linear, de Lasso e Ridge.....	27
Figura 10 - Influência dos insumos básicos na resistência à compressão do concreto autoadensável.....	28
Figura 11 - Influência dos aditivos na resistência à compressão do concreto autoadensável. 29	
Figura 12 - Influência dos aditivos na resistência à compressão do concreto autoadensável. 30	
Figura 13 - Previsão da resistência à compressão através de diferentes modelos de regressão linear	30
Figura 14 - Previsão da resistência à compressão através da árvore de decisões.....	31
Figura 15 - Previsão da resistência à compressão através da floresta aleatória	31
Figura 16 - Correlação de atributos para árvore de decisões e floresta aleatória.	32
Figura 17 - Métricas de avaliação para os cinco modelos de regressão utilizados.	33

LISTA DE TABELAS

Tabela 1 - Resumo das bases literárias encontradas.....	14
Tabela 2 - Resumos de contribuições dos materiais básicos na resistência a compressão.....	20
Tabela 3 - Resumos de contribuições dos aditivos e adições na resistência.	22
Tabela 4 - Resumos de correlações entre atributos de materiais básicos	24
Tabela 5 - Resumos de correlações entre atributos de aditivos e adições	25
Tabela 6 - Resumo das métricas RMSE e R^2 dos modelos analisados.....	34
Tabela 7 - Tempo apresentado para o processamento de cada modelo para treinamento e predição da variável objeto.....	34

SUMÁRIO

1	INTRODUÇÃO	9
2	METODOLOGIA.....	12
2.1	Banco de Dados, Instâncias, Atributos e Variável Resultado.....	13
2.2	Análise Exploratória.....	15
2.3	Pré-Processamento do Banco de Dados.....	16
2.4	Modelos Implementados.....	16
2.5	Métricas de Avaliação dos Modelos.....	17
2.6	Detalhes da Implementação.....	17
3	RESULTADOS E DISCUSSÕES	19
3.1	Análise Estatística Exploratória.....	19
3.2	Previsão da Resistência à Compressão.....	27
3.3	Gasto Computacional dos Modelos.....	34
4	CONCLUSÃO	36
	REFERÊNCIAS	38
	APÊNDICE 1 – RECORTE DO BANCO DE DADOS INICIAL.....	43
	APÊNDICE 2 – RECORTE DO BANCO DE DAOS ORGANIZADO	
	PARA O PRÉ-PROCESSAMENTO	46

1 INTRODUÇÃO

Segundo Monteiro, Miller, Horvath (2017, p. 698), o concreto é o segundo material mais consumido no mundo depois da água, com um consumo aproximado de 30 bilhões de toneladas anual. Neste sentido, métodos que otimizem o aproveitamento dos materiais e reduzam os desperdícios, são entendidos como contribuições ao uso racional e sustentável de recursos. Tendo em vista a otimização da produção do concreto e seus constituintes, é natural que ocorram melhorias na sua composição através da incorporação de aditivos e adições (MONTEIRO; MILLER; HORVATH, 2017).

Por conseguinte, é possível verificar adaptações nas formações do compósito ao longo dos anos, com formulações para que possa atender a diferentes demandas e aplicações desse material, principalmente no que se refere à incrementos de resistência e melhorias das propriedades no estado fresco e endurecido.

O concreto pode ser caracterizado quanto à sua composição pelo consumo individual de cada insumo, podendo ou não conter aditivos e adições que contribuam para modificação de suas características (METHA; MONTEIRO, 2008). Dentre as principais características do concreto, a resistência à compressão axial ainda é seu principal requisito mecânico, tendo em vista sua aplicação estrutural. A dosagem adequada e a qualidade dos componentes presentes no concreto são essenciais para a garantia da resistência projetada (METHA; MONTEIRO, 2008).

Apesar da ampla utilização do concreto em diversas aplicações, a produção do concreto convencional, o tipo mais usual, implica na necessidade de vibração após o lançamento nas formas, para o melhor preenchimento e adequação à forma da estrutura. Tal aspecto implica no aumento da quantidade de mão de obra, tempo de serviço, resumindo em custos excedentes, e podendo resultar em surgimento de danos, quando mal executado (PROMSAWAT *et al*, 2020; CHENG; SHEN, 2021). Como alternativa para esse problema, foi desenvolvido no Japão, na década de 1980, as primeiras formulações de concreto autoadensável (CAA) (DOUMA *et al.*, 2017; DOMONE *et al.* 1998).

Conforme norma NBR 15823-1, o CAA deve possuir capacidade de adensamento sob ação do próprio peso, elevada fluidez e homogeneidade em seu estado fresco, com habilidade passante entre ferragens e resistência à segregação nas etapas de manuseio da mistura, eximindo a necessidade de vibração ou manuseios correlatos (ABNT, 2017). Dentre outras vantagens do

concreto autoadensável, é evidenciada a redução de custos laborais, redução do tempo de construção, mitigação de vibração e ruídos, melhor fluidez para espaçamentos menores e melhor acabamento. Devido a esses fatores a utilização desse concreto tem crescido mundialmente (GOWRIPALAN; SHAKOR; ROCKER, 2021)

Mesmo com propostas iniciais estimadas do traço, o processo de dosagem de concretos está intimamente relacionado a métodos teórico-empíricos que tornam esse processo laboratorial oneroso (SHI et al., 2015). Para a dosagem do concreto autoadensável, esse contexto é ainda mais complexo em função de suas características no estado fresco.

O processo de dosagem ainda é uma metodologia de estimativas, onde a previsão das características requeridas é realizada também com base em dosagens prévias, e esse tipo de problema se encaixa em escopos de outras áreas do conhecimento, como *Data Science* e *Machine Learning* da tecnologia da informação.

A inteligência artificial (IA) tem sido objeto de estudo nos últimos anos, principalmente em função da sua potencialidade em inúmeras aplicações (KUMAR, 2017; WANG; MAN, 2021; RYMAN-TUBB; KRAUSE; GARN, 2018). Estudos acerca dessa tecnologia vão desde a detecção de fraudes em sistemas de pagamento (RYMAN-TUBB; KRAUSE; GARN, 2018; YAZICI, 2020), até aplicações na medicina, como no diagnóstico de COVID-19 através de imagens de raio-X (BORKOWSKI, 2020; SALMAN et al., 2020), passando por aplicações em Engenharia Civil.

Na construção civil também há aplicações já existentes, como por exemplo na detecção de falhas em pavimentos asfálticos (PAZ et al., 2020), detecção de danos em pontes (SUN et al., 2020) na estimativa da resistência à compressão de concretos (VAN DAO et al., 2019) módulo de elasticidade (SADATI et al., 2019), dentre outros.

Modelos de IA categorizam os resultados de previsão em alguns tipos principais de problemas, onde apenas dois serão utilizados: os de classificação, onde se pretende estimar uma categoria pré-definida (BHATTACHARYA; SOLOMATINE, 2006), e os de regressão, para estimativa de parâmetros numéricos, como a estimativa de resistência à compressão ou cisalhamento (PHAM et al., 2018; FENG et al., 2020).

A aprendizagem em si, termo empregado para o ajuste desses modelos de IA, pode ocorrer de forma supervisionada ou não supervisionada. A primeira envolve a rotulação prévia do conjunto de entradas, o que não ocorre no segundo. Um mesmo problema pode ser abordado de uma forma supervisionada (SARMADI; ENTEZAMI, 2021), ou não supervisionada (ENTEZAMI; SHARIATMADAR; SARMADI, 2020), onde sua precisão dependerá da forma de sua implementação e do tipo de dados analisados.

A avaliação desses modelos de regressão após treinamento possui várias métricas, muitas dessas derivadas da própria estatística. Dentre as mais utilizadas é possível elencar o *root mean squared error* (RMSE) que é a medida que calcula a raiz quadrada média dos erros entre valores reais e previstos, usado na regressão, o *mean absolute error* (MAE) que calcula o erro médio absoluto e o coeficiente de determinação R^2 , que representa a aderência de resultados do modelo a observações reais, associado à regressão linear. Nos dois primeiros buscam-se os menores resultados possíveis, enquanto no terceiro objetiva-se valores próximos de 1.

Além das métricas estatísticas para a verificação da precisão e desvio padrão dos modelos, como forma de análise da performance, foi verificado também o gasto computacional apresentado por cada modelo implementado (Regressores lineares, *Decision Tree*, *Random Forest*, *Multilayer Perceptron*) através do tempo de processamento para cada implementação. O tempo apresentado verifica o gasto computacional referente à predição da variável de interesse, como também o tempo para o treinamento do modelo.

Nesse contexto, o presente estudo se propõe a analisar a performance dos modelos de regressão citados aplicados a dados de resistência à compressão, para a estimativa da resistência à compressão de concretos autoadensáveis (CAA) a partir de dosagens de consumo e caracterização dos materiais. Inicialmente é realizada com uma análise exploratória de dados, para avaliação da correlação entre os principais atributos no banco dados gerado, com destaque para as correlações de maior evidência.

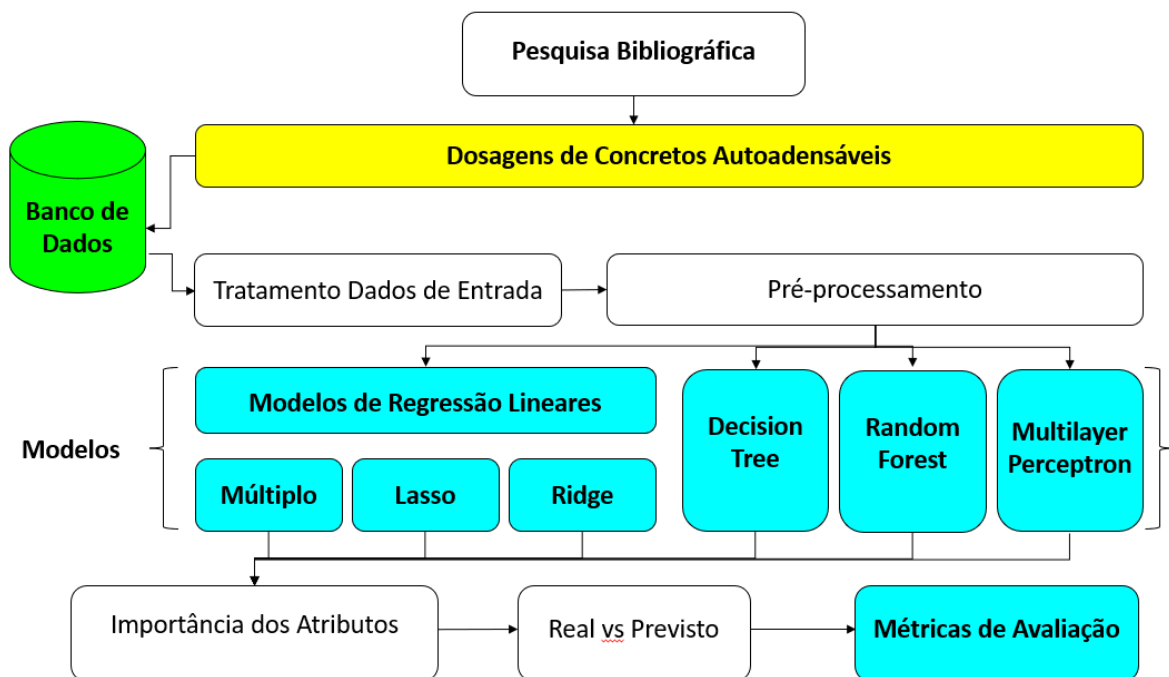
Esse trabalho contribui tanto para a avaliação preliminar de modelos simplificados de IA antes da implementação de modelos mais robustos, quanto para a organização de dados da literatura na forma estruturada de um banco de dados, para uso futuro por outros pesquisadores em pesquisas relacionadas à dosagem de CAA.

2 METODOLOGIA

A metodologia do presente trabalho constituiu-se, inicialmente, pela obtenção de um banco de dados composto por dosagens de concreto autoadensável, através de pesquisa bibliográfica em artigos nacionais e internacionais, utilizando plataformas como Periódico CAPES, *Science Direct* e *Engineering Village*. Dos 17 artigos utilizados, foi possível organizar um banco de dados inicial com 505 dosagens de concreto autoadensáveis. Posteriormente, procedeu-se com o tratamento das informações coletadas, a organização dos dados, definição e implementação dos modelos de aprendizagem, de forma a estimar a resistência à compressão em cada situação, e assim analisar a performance entre eles.

Conforme apresentado no fluxograma da Figura 1, o tratamento dos dados de entrada e o pré-processamento podem ser definidos como a etapa de homogeneização dos dados de dosagens coletados dos artigos, para apresentá-los de uma forma unificada, e assim permitir que sejam analisados pelo modelo de inteligência artificial (IA).

Figura 1 - Fluxograma da Metodologia empregada no trabalho.



Fonte: Autor, 2022.

Após o treinamento inicial dos modelos foi possível verificar a importância de cada componente da dosagem na resistência à compressão, incluindo também a avaliação de aditivos e adições. Ao final, com os modelos de previsão treinados, pode-se comparar os valores reais versus o previsto, com base na divisão de dados como 80% para treino 20% para teste. A partir

da comparação realizada, foram definidas as métricas de avaliação apresentadas nos resultados de precisão de cada modelo, desvio padrão, além do esforço computacional em cada processamento específico.

2.1 Banco De Dados, Instâncias, Atributos e Variável Resultado

Pode-se descrever um banco de dados como um conjunto de dados, em textos ou números, que se apresentam de forma estruturada ou não estruturado, de forma lógica, e possuam um significado inerente ao seu contexto (ELMASRI; NAVATHE, 2015). No presente estudo, o banco de dados elaborado é composto por um conjunto de instâncias que apresentam os mesmos atributos.

Por instâncias entende-se como cada dosagem coletada na literatura, ou seja, cada linha do banco de dados corresponde a um traço obtido da pesquisa bibliográfica. Os atributos referem-se aos materiais que compõem a mistura do concreto definido em cada dosagem. Dessa forma, podemos afirmar que as instâncias são compostas de atributos, e resumir como os atributos correspondem às colunas e as instâncias às linhas na “tabela” do banco de dados.

A coleta de instâncias para compor o banco de dados foi realizada por meio de pesquisa bibliográfica em artigos científicos nacionais e internacionais que versam sobre CAA. Foram escolhidos artigos que possuíam além do consumo de materiais, que é a característica mais usual, as caracterizações dos materiais utilizados, como massa específica, tipo de materiais, dentre outros. Todas as dosagens que não possuíam os dados mínimos de massa específica não foram incluídas.

Dados como fator água-cimento, percentual em relação à massa de aglomerante, dentre outros, foram convertidos para consumo unitário em quilograma por metro cúbico (kg/m^3), coincidindo com as unidades de massa específica. O resumo dos artigos utilizados é apresentado na Tabela 1.

Tabela 1 - Resumo das bases literárias encontradas.

Referência	Número de Instâncias	Autor
1	123	(KONERU; GHORPADE, 2019)
2	28	(TUTIKIAN, 2004)
3	8	(BENAICHA et al., 2019)
4	69	(ABU YAMAN; ABD ELATY; TAMAN, 2017)
5	114	(BELALIA DOUMA et al., 2017b)
6	15	(BASU; GUPTA; AGRAWAL, 2020)
7	12	(FERREIRA; RIBEIRO, 2018)
8	3	(ALMEIDA FILHO et al., 2008)
9	3	(ALESSANDRO ALMEIDA DINIZ et al., 2018)
10	65	(GÜNEYISI; GESOLU; ÖZBAY, 2010)
11	12	(JALAL; MANSOURI, 2012)
12	10	(RAMANATHAN et al., 2013)
13	10	(SUKUMAR; NAGAMANI; SRINIVASA RAGHAVAN, 2008)
14	10	(BOUZOUBAÂ; LACHEMI, 2001)
15	9	(BOEL et al., 2007)
16	7	(NEHDI; PARDHAN; KOSHOWSKI, 2004)
17	7	(BINGÖL; TOHUMCU, 2013)
Total	505	

Fonte: Autor, 2022.

Após a organização e homogeneização inicial dos dados, mantiveram-se 503 dosagens para a composição do banco de dados, devido à falta de alguns atributos em algumas instâncias. O banco de dados foi desenvolvido utilizando o Google Planilhas.

As informações das dosagens, os dados de entrada, foram divididos em três categorias principais: consumo de materiais básicos, como cimento, areia, brita e água, consumo de materiais adicionais (aditivos e adições), como sílica ativa, plastificantes, dentre outros, e dados de caracterização das resistências, mas mantendo como foco principal a análise da resistência à compressão axial, conforme apresentado no Apêndice 1.

Foi realizado um tratamento inicial dos dados para a padronização das métricas de consumos dos materiais que consistiu na conversão das instâncias para unidades de consumo

de material em massa de um dado material por volume de concreto utilizando a mesma unidade para os dados de massa específica (kg/m^3).

Ao final, o banco de dados utilizado compreendeu um total de 503 instâncias, com 18 atributos cada, com características de consumo, massas específicas e resistência, sem valores faltantes.

2.2 Análise Exploratória

Para a determinação de um bom modelo de previsão, é necessário primeiramente analisar o conjunto de dados a ser processado (*dataset*). Durante essa análise, investigam-se correlações entre atributos, suas distribuições de frequência, bem como suas relações com a variável resposta, neste caso, a resistência à compressão.

Nessa etapa, ilustrações como mapas de calor (*heatmap*), plotagem de pares cruzadas (*pairplots*), gráficos de pontos ponderados (*weighted scatterplot*), dentre outros, foram elaborados. Cada um desses possui a capacidade de evidenciar tendências específicas do *dataset* em geral, não percebidas inicialmente, sendo possível evidenciar comportamentos também inerentes aos modelos que serão gerados (STORME; DERUDDER; DÖRRY, 2019). Tais correlações devem ser discutidas de maneira a associar a explicações físicas ligadas a atributos de entrada como quanto ao comportamento físico-químico dos materiais constituintes do concreto no caso deste estudo.

Os mapas de calor gerados, utilizam uma metodologia de correlação de variáveis conhecida como Correlação de Pearson, que evidencia correlações variacionais que duas variáveis têm entre si. O fator de correlação varia de -1 a 1, sendo que quanto mais próximo de 1 maior a correlação variacional, e quanto mais próximo de -1 inversamente relacionadas, e o 0 indica que não há correlação entre as variáveis analisadas. O coeficiente de correlação de Pearson é calculado através do somatório do produto dos desvios padrões das duas variáveis, dividido pelo número de dados utilizados.

A exemplo físico, tem-se o fator água-cimento, conhecido também como Lei de Abrams, que apresenta uma correlação entre a proporção água-cimento com inferência na resistência do concreto (METHA; MONTEIRO, 2008). Quanto maior esse fator, menor será a resistência do concreto, configurando neste caso uma relação destrutiva entre o consumo de água e a resistência à compressão, para o mesmo consumo de cimento. Após a análise exploratória de dados espera-se obter correlações similares nos modelos implementados.

2.3 Pré-Processamento Do Banco De Dados

Técnicas de pré-processamento consistem na adequação e otimização do *dataset* para serem submetidos aos modelos de aprendizagem. Primeiramente é feita a homogeneização dos dados, que se refere a um tratamento para expressar todos os dados da forma mais homogênea possível. Essa etapa é necessária, pois as dosagens obtidas nos artigos se apresentavam de formas distintas, no que se refere à quantidade de aditivos ou adições na mistura, entre outros.

Para os modelos que aqui serão utilizados, todas as instâncias deverão possuir o mesmo tamanho, para que então seja feita sua normalização, que consiste no escalonamento dos atributos em si, conforme é possível visualizar no resultado expresso no Apêndice 2.

Para otimizar o processamento dos modelos de aprendizagem é aconselhável que os valores de entrada estejam entre 0 e 1, para que todos os dados sejam apresentados em intervalos similares, sem distorcer informações para a análise obtida. Diante disso, foi utilizada uma implementação da biblioteca *Sklearn* nominada com *StandartScaler*.

2.4 Modelos Implementados

Realizada uma pesquisa bibliográfica sobre o tema de modelos de aprendizagem para determinação de propriedades de materiais, foi possível perceber que existe uma tendência à adoção de modelos de redes neurais artificiais como modelo de solução para diversos problemas (LY *et al.*, 2021; IKUMI *et al.*, 2021; CONGRO *et al.*, 2021). Isso ocorre devido à sua versatilidade e a sua capacidade de adaptação, contudo são implementações que possuem alta demanda de processamento.

As redes neurais artificiais consistem em modelos computacionais de análise, treinamento (aprendizagem) que podem ser usados para previsão, através de modelos matemáticos que simulam algo simples do sistema nervoso de animais (CARVALHO, 2009). Essas redes podem aproximar valores de resposta de qualquer função computável com uma certa precisão (WANG, 2003).

Neste estudo foi analisada a viabilidade de modelos mais simples como regressões lineares (incluindo as variações de Lasso e Ridge), regressores de árvores de decisão (*decision tree regressor*) e floresta aleatória (*random forest regressor*) onde os modelos mais simples possuem boa capacidade de previsão, a depender do problema estudado e *dataset*, com demanda computacional consideravelmente menor.

Os modelos Lasso e Ridge também são lineares, com diferença na otimização dos coeficientes, buscando sua minimização no primeiro caso, e otimizando pela soma dos quadrados no segundo. Já os regressores de árvores de decisão e floresta aleatória baseiam-se na divisão progressiva e segmentação dos dados observados, similar às divisões de ramos e folhas de uma árvore (Árvore de Decisão), com atenção especial ao segundo modelo, por se tratar de um conjunto de árvores de decisões (Floresta Aleatória).

O último modelo de baixo consumo computacional implementado foi o regressor polinomial, que apesar do nome, não possui uma correlação direta com modelos matemáticos de regressão polinomial se tratando na verdade de um modelo também linear, usualmente conhecido como regressão logística. Também foi implementado modelos de rede neural mais simples como *Multilayer Perceptron* (MLP), que possui estruturas similares aos modelos de redes neurais mais robustos, com simplificações em sua concepção.

2.5 Métricas De Avaliação Dos Modelos

Cada modelo deve ser avaliado conforme as próprias dinâmicas de construção. Em regressão, deve-se investigar o desvio entre previsão e medida real e esse desvio é quantificado de diversas formas.

Este trabalho utiliza quatro métricas para avaliação das modelagens geradas: o desvio médio quadrático ou *root mean squared error* (RMSE) que é a medida que calcula a raiz quadrada média dos erros entre valores reais e previstos; o erro absoluto médio ou *mean absolute error* (MAE) que calcula o erro médio absoluto; o coeficiente de determinação R^2 , que representa a medida de aderência dos resultados do modelo às observações reais, e o tempo de treino e predição de cada modelo para quantificação do gasto computacional.

2.6 Detalhes Da Implementação

A implementação dos modelos e análises por aprendizado de máquina foi codificado na linguagem *Python*, através do Ambiente de Desenvolvimento Integrado de código aberto *Anaconda Environment 3*. Para importação e construção do *dataset*, foi utilizada a biblioteca *Pandas*, que é uma ferramenta de código aberto aplicada para análise e manipulação de dados, com o auxílio da biblioteca *NumPy*, que possui funções matemáticas e suporta o processamento de matrizes e arranjos numéricos de grandes dimensões, aplicada ao tratamento numérico do banco de dados, conforme apresentado na Figura 2. Para as análises estatísticas iniciais, a

biblioteca *Seaborn*, permitindo a visualização em gráficos dos dados. O escopo geral da implementação segue o fluxograma apresentado na Figura 1.

Figura 2 - Listagem das bibliotecas utilizadas, para os processamentos e análises iniciais.

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import rcParams

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# Importing models
from sklearn.linear_model import LinearRegression, Lasso, Ridge
from sklearn.tree import DecisionTreeRegressor
from sklearn.ensemble import RandomForestRegressor
```

Fonte: Autor, 2022.


3 RESULTADOS E DISCUSSÕES

Na seção 3.1 é apresentada a análise exploratória inicial dos dados. Nessa seção é possível visualizar mapas de correlação, gráficos de distribuição, dentre outros, onde se pretende discutir as principais tendências expressas pelos modelos implementados. Posteriormente, é apresentado o resultado das implementações dos modelos de regressão através da avaliação das métricas de desempenho.

3.1 Análise Estatística Exploratória

A Figura 3 apresenta o *heatmap* para atributos dos materiais básicos e resistência à compressão. Ele utiliza a correlação de Pearson, incorporada à biblioteca Seaborn. Os valores observados variam entre -0,68 a 0,67, adimensional, sendo essa a faixa de resultados a serem discutidos. A interpretação é comparativa entre os valores obtidos.

Figura 3 - Heatmap de correlação entre atributos de materiais básicos e variável resultado.



Fonte: Autor, 2022.

Analisando as influências na resistência à compressão, última linha ou coluna da matriz apresentada no *heatmap*, é possível observar a maior correlação positiva do consumo de cimento (0,36), seguido por sua respectiva massa específica (0,25), possuindo também forte

influência do consumo do agregado graúdo (0,13). Os demais atributos apresentaram correlação negativa, valendo ressaltar que tanto o consumo de agregado miúdo quanto o consumo de água apresentaram as mais baixas correlações, da ordem de -0,20, em função da resistência. Em sentido físico, significa interpretar que o aumento do consumo de agregado miúdo é tão prejudicial quanto o consumo de água para a resistência final do concreto.

Analisando as correlações entre os atributos em geral (análise entre componentes), é visualizado que a maior correlação positiva ocorre entre os consumos de cimento e água (0,67). Nesse caso, o aumento do consumo de cimento implica em uma maior demanda de água, necessária para ocorrer a hidratação do cimento Portland, relacionado também com a lei de Abrams, mantendo fatores água-cimento próximos para diversos CAAs, sendo esse comportamento previsível até então.

A segunda maior correlação é seguida pelas massas específicas dos agregados miúdo e graúdos (0,60), onde é possível estimar correlações com a origem desses materiais e seus processos de formação.

Em contrapartida, a maior correlação negativa ocorre em relação aos consumos desses últimos insumos em si (-0,68), significando que o aumento do consumo de um implica na redução do segundo, o que possui relação com o sentido de empacotamento dos materiais. Podemos evidenciar as contribuições de valores mais representativos na tabela 2.


Tabela 2 - Resumos de contribuições dos materiais básicos na resistência a compressão.

Item	Coefficiente Estatístico	Atributo de Dosagem com Influência na Resistência
1	0,36	Consumo de Cimento
2	0,25	Massa Específica do Cimento
3	0,13	Consumo de Agregado Graúdo
4	(-0,17)	Massa Específica do Agregado Graúdo
5	(-0,19)	Consumo de Água
6	(-0,20)	Consumo de Agregado Miúdo

Fonte: Autor, 2022.

A Figura 4 apresenta o mapa de calor para atributos dos aditivos, adições e resistência à compressão. Os coeficientes estão normalizados, variando entre -0,25 a 0,39.

Figura 4 - Heatmap de correlação entre atributos de aditivos, adições e variável resultado.



Fonte: Autor, 2022.

Analisando as influências na resistência à compressão, é possível observar uma alta correlação positiva do consumo de superplastificante (0,25), igualado ao consumo de escória de alto forno (0,25). A adição de superplastificante permite reduzir o fator água-cimento mantendo a trabalhabilidade, logo o ganho de resistência expresso pela correlação é esperado. Quanto à escória de alto forno, suas propriedades pozolânicas são verificadas através de sua composição, sendo atualmente utilizado como material adicional ao cimento Portland na produção de concreto (COUTO, *et al*, 2010). Logo seu acréscimo na dosagem implicará diretamente no aumento da resistência à compressão.

Os atributos do modificador de viscosidade, sílica ativa e metacaulim obtiveram correlações menores, porém com contribuições positivas, enquanto os demais foram todos negativos, em especial a cinza de casca de arroz com a contribuição de menor valor (-0,17).

Analisando a correlação negativa do aditivo da cinza da casca de arroz, podemos verificar que apresenta um comportamento divergente do que é apresentado na literatura, onde

vemos que esse material apresenta propriedades pozolânicas, permitindo uma substituição parcial do cimento, mantendo os resultados de resistência esperados (BIXAPATHI; SARAVANAN, 2021), fator que pode ser verificado em trabalhos futuros.

Analisando as correlações entre os atributos é perceptível que a maior correlação positiva ocorre entre os consumos de pó de pedra e modificador de viscosidade (0,67), seguido pela relação entre o consumo de cinza volante e o de incorporador de ar (0,21). Em contrapartida, a maior correlação negativa ocorre em relação ao consumo da cinza em comparação à sílica ativa (-0,68), o que pode ser explicado pela similaridade de função que ambos têm no CAA, de dar coesão e permitir ganhos de resistência posteriores, de maneira que na maior presença de um, menos é necessário do outro.

Podemos verificar também um resumo das contribuições dos aditivos e adições na resistência, conforme tabela 3.

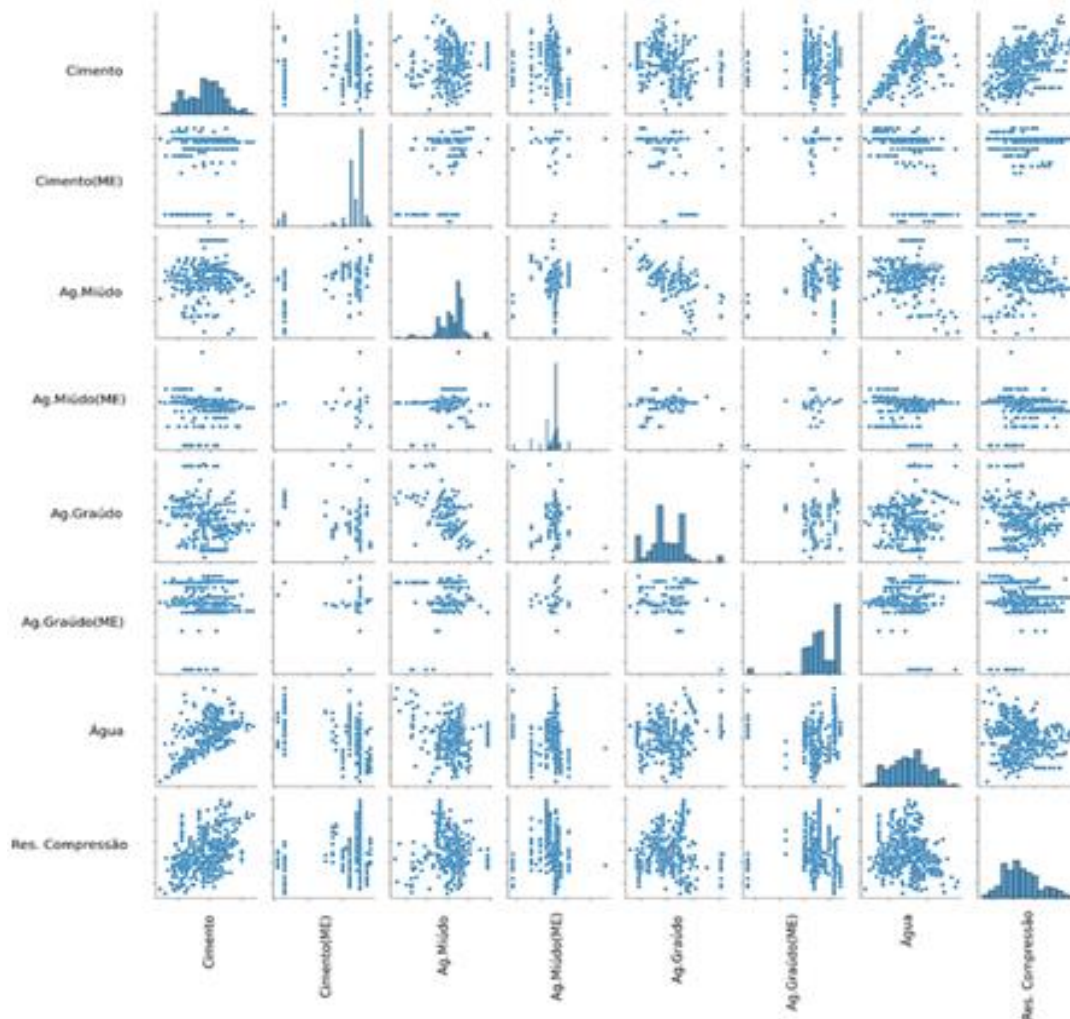
Tabela 3 - Resumos de contribuições dos aditivos e adições na resistência.

Item	Coefficiente Estatístico	Atributo de Dosagem com Influência na Resistência
1	0,25	Consumo Superplastificante e Escória de Alto Forno
2	0,099	Consumo de Modificador de Viscosidade
3	0,085	Consumo de Sílica Ativa
4	(-0,094)	Consumo de Cinza Volante
5	(-0,10)	Consumo de Incorporador de Ar
6	(-0,17)	Consumo da Cinza da casca de arroz

Fonte: Autor, 2021.

A Figura 5 apresenta o *pairplot* com a correlação entre os materiais básicos e a resistência à compressão. Os gráficos apresentam as combinações dois a dois de cada atributo em acréscimo à variável de saída.

Figura 5 - *Pairplot* de correlação entre materiais básicos e variável resultado.



Fonte: Autor, 2022.

O comportamento observado dos dados apresenta diferenças significativas para diferentes pares de variáveis, resultado das diferentes correlações existentes entre os materiais básicos e a resistência à compressão. Essencialmente, o par consumo de cimento x consumo de água apresenta uma tendência linear, indicando que um acréscimo no consumo de cimento resultaria em um aumento no consumo de água, portanto, definida por uma função linear.

Também é possível visualizar uma tendência à linearidade no par consumo de cimento x resistência à compressão, justificada pelo aumento da resistência em função do aumento do consumo de cimento, correlação amplamente difundida em função das próprias características do material cimentício. Podemos verificar um resumo das correlações entre atributos de materiais básicos, conforme tabela 4.

Tabela 4 - Resumos de correlações entre atributos de materiais básicos

Item	Coefficiente Estatístico	Correlações entre Atributos
1	0,67	Consumo de Água x Consumo de Cimento
2	0,60	M.E. Agregado Graúdo x M. E. Agregado Miúdo
3	0,35	M. E. Agregado Graúdo x Consumo de Agregado Miúdo
4	(-0,32)	Consumo de água x M.E. Cimento
5	(-0,42)	M.E. Agregado Graúdo x Consumo de Agregado Graúdo
6	(-0,68)	Consumo de Agregado Graúdo x Consumo de Agregado Miúdo

Fonte: Autor, 2022.

A Figura 6 evidencia o *pairplot* com a correlação entre os aditivos, adições e resistência à compressão. Os valores estão normalizados e mostram de forma gráfica as possíveis associações entre as variáveis.

Figura 6 - *Pairplot* de correlação entre atributos de aditivos, adições e variável resultado.

Fonte: Autor, 2022.

O comportamento dos dados apresenta diferenças significativas entre eles, resultado das diferentes correlações existentes entre os consumos de aditivos e adições e a resistência à compressão. De forma geral, a dispersão dos dados observada na maioria dos pares indica a baixa correlação entre eles, individualmente, com a resistência à compressão.

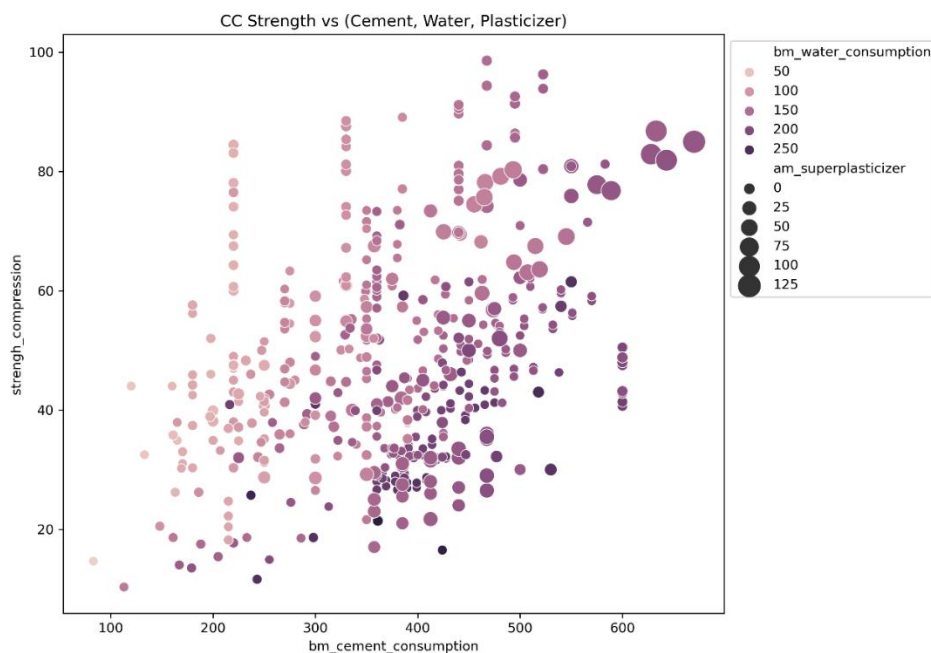
Essencialmente, entre os aditivos, o par superplastificante x resistência à compressão apresentou uma tendência próxima à linear, assim como o par modificador de viscosidade x resistência à compressão. Já entre as adições, a correlação mais próxima da linearidade foi observada entre o par cinza volante x resistência à compressão. Em resumo, podemos verificar na Tabela 5 as correlações entre atributos de aditivos e adições. A Figura 7 indica uma correlação entre diferentes insumos do concreto autoadensável e a resistência à compressão.

Tabela 5 - Resumos de correlações entre atributos de aditivos e adições

Item	Coefficiente Estatístico	Correlações entre Atributos (consumos)
1	0,39	Pó de Pedra x Mod. de Viscosidade
2	0,21	Cinza Volante x Incorporador de Ar
3	0,18	Cinza Volante x Superplastificante
4	(-0,19)	Filler Calcário x Cinza Volante
5	(-0,25)	Cinza Volante x Sílica Ativa
6	(-0,26)	Cinza Volante x Metacaulim

Fonte: Autor, 2022.

Figura 7 - Relação entre consumo de cimento, água, superplastificante e resistência à compressão do concreto autoadensável.



Fonte: Autor, 2022.

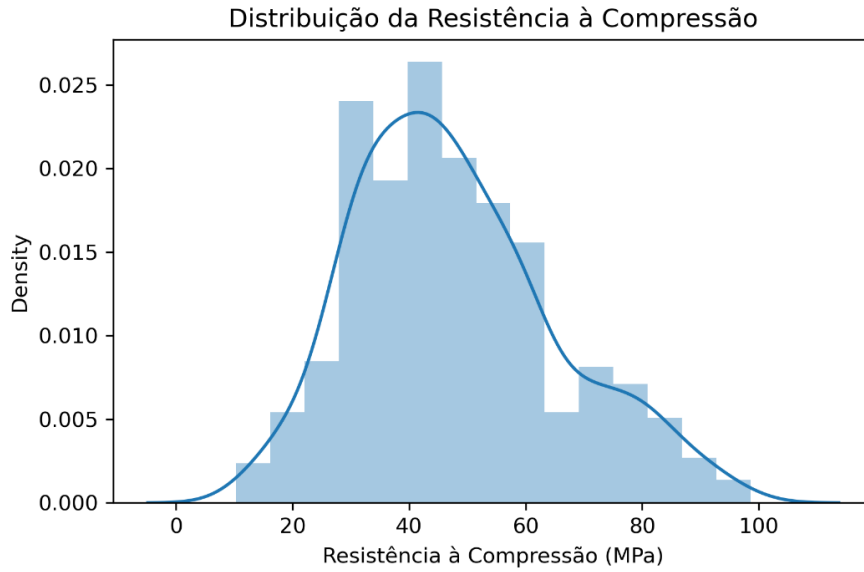
Por meio da Figura 7, percebe-se que à medida que o consumo de cimento aumenta, ocorre uma tendência ao aumento da resistência à compressão do concreto, com maior quantidade de dados localizados entre os intervalos de 400 kg/m³ e 500 kg/m³ de consumo de cimento com relação ao volume de concreto.

Da mesma forma, é evidenciada a relação entre o consumo de água e a resistência, indicando uma tendência à obtenção de maiores valores de resistência relacionados ao consumo baixo e intermediário de água, entre 50 kg/m³ e 150 kg/m³, ao passo que para maiores valores do seu consumo, observa-se menor resistência.

Quanto à utilização de superplastificante, observa-se tendência à maior utilização desse aditivo para maiores quantidades de consumo de cimento, como observado nos valores superiores a 600 kg/m³ de consumo desse insumo.

A resistência à compressão dos concretos dispostos no banco de dados tem sua distribuição apresentada na Figura 8.

Figura 8 - Curva e histograma das resistências à compressão observadas




Fonte: Autor, 2022.

Percebe-se através da distribuição apresentada, uma tendência à obtenção de concretos autoadensáveis com a resistência média de 47,92 MPa, com desvio padrão de 17,51 MPa. A obtenção de concretos autoadensáveis com resistência superior a 50 MPa possui uma densidade menor de amostras distribuídas no banco de dados. Apresenta também uma leve descontinuidade na tendência geral, nas faixas de 35 a 40 MPa e de 60 a 70 MPa.

3.2 Previsão Da Resistência à Compressão

A escolha do algoritmo que melhor se adequa ao problema ocorre em função do treino e da performance de cada um deles, sendo aquele com melhores resultados segundo as métricas adotadas, o recomendável a ser utilizado na previsão dos dados. Os coeficientes determinados para a regressão linear, regressão de Lasso e regressão de Ridge podem ser observados na Figura 9.

Figura 9 - Disposição dos coeficientes determinados para as regressões linear, de Lasso e Ridge




Fonte: Autor, 2022.

De modo geral, percebe-se que a regressão linear e a regressão de Ridge apresentam valores próximos entre si de coeficientes da equação linear, conforme apresentado no gráfico, ao passo que a regressão de Lasso apresentou valores mais próximos de zero em relação às demais regressões.

Para melhor auxiliar na compreensão, os dados da Figura 8 foram divididos em 3 partes, sendo a primeira com a utilização dos consumos básicos necessários à produção de um concreto (agregados, água e cimento), a segunda com os aditivos e a terceira com as adições. A coluna em azul representa o coeficiente observado através da regressão linear múltipla, a coluna em amarelo representa o coeficiente observado através da regressão de Lasso e a coluna verde representa a regressão de Ridge.

Através da correlação apresentada na Figura 9, foi possível analisar a influência de diferentes insumos na produção do concreto. Para os insumos básicos, foram definidos os itens apresentados na Figura 10.

Figura 10 - Influência dos insumos básicos na resistência à compressão do concreto autoadensável.



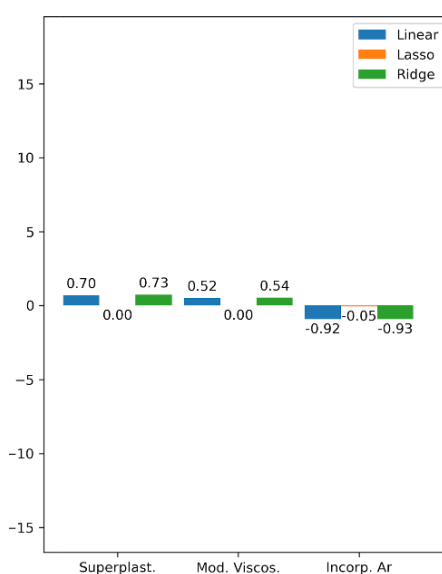
Fonte: Autor, 2022.

Com a Figura 10, é possível observar uma maior correlação entre o consumo de cimento e de agregado graúdo na resistência à compressão do concreto, para as três regressões em análise. Nomeadamente, o coeficiente observado para o consumo de cimento na regressão Linear, regressão de Lasso e Regressão de Ridge, foram equivalentes a 17.89, 13.55 e 17.61, respectivamente. Já, para o consumo de agregado graúdo, esse valor foi equivalente a 6.69, 2.96 e 6.49, respectivamente.

Em contrapartida, a influência do consumo de agregado miúdo se apresentou próxima a zero nos três modelos analisados, com valores de 0.77, -0.99 e 0.59. A água, por sua vez, apresentou uma elevada correlação negativa, com -15.03, 10.83 e -14.92, respectivamente, indicando o efeito que o aumento no consumo desse insumo pode contribuir na redução da resistência do concreto.

Com respeito à utilização de aditivos, os dados em análise são identificados na Figura 11. Nela, é mostrada a influência dos aditivos superplastificantes, modificador de viscosidade e incorporador de ar.

Figura 11 - Influência dos aditivos na resistência à compressão do concreto autoadensável.




Fonte: Autor, 2022.

A utilização de aditivos na composição do CAA tem como principal função o ajuste das suas propriedades reológicas, permitindo atender aos critérios pré-definidos em norma a respeito do seu estado fresco. Com isso, através da Figura 11, pode-se perceber uma baixa influência dos aditivos utilizados na resistência à compressão do concreto. Isso se deve ao fato de que esses aditivos são utilizados para alterações no estado fresco do concreto, com baixa influência no aumento ou redução da resistência no estado endurecido.

A Figura 12 apresenta os dados relativos às adições apresentadas nos concretos usados no banco de dados.

Figura 12 - Influência dos aditivos na resistência à compressão do concreto autoadensável.




Fonte: Autor, 2022.

Dentre as adições analisadas, o fíler calcário apresentou maior correlação com a resistência à compressão do concreto, com coeficiente observado para a regressão linear, regressão de Lasso e regressão de Ridge equivalentes a 5.10, 1.91 e 4.97, respectivamente. De forma geral, percebe-se também uma influência das adições pozolânicas, como o metacaulim e a sílica ativa, apresentando correlação direta com a resistência. Em contrapartida, o pó de pedra e a cinza volante apresentaram menores coeficientes com a resistência à compressão do CAA.

A predição da resistência pode ser observada na Figura 13, em que se podem ver as três regressões e a disposição dos valores observados no treinamento do modelo.

Figura 13 - Previsão da resistência à compressão através de diferentes modelos de regressão linear



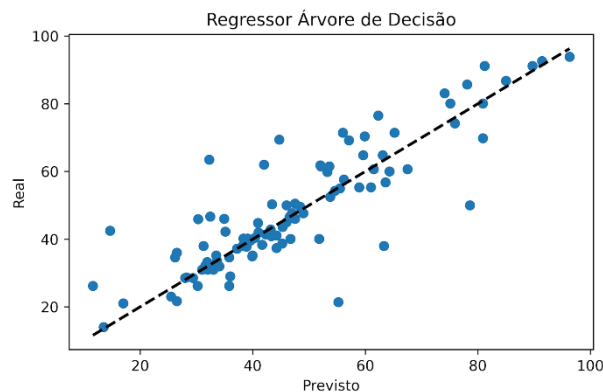
Fonte: Autor, 2022.

Os valores referentes ao eixo Y representam os dados reais de resistência à compressão, definidos no banco de dados, enquanto o eixo X corresponde aos valores encontrados através das regressões.

Para a regressão linear, os valores de RMSE e R^2 , foram respectivamente 10.28 e 65.8%, ao passo que para as regressões de Lasso e Ridge, esses valores foram 10.89 e 61.1% para a regressão de Lasso e 10.29 e 65.7%, para a regressão de Ridge.

Os dois últimos modelos utilizados foram a árvore de decisões e a floresta aleatória. Para a árvore de decisões, foi utilizada como outro modelo para auxiliar na predição da resistência à compressão do CAA.

Figura 14 - Previsão da resistência à compressão através da árvore de decisões

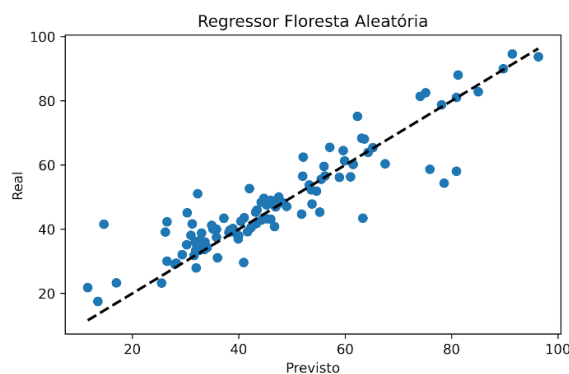


Fonte: Autor, 2022.

Para a árvore de decisões, foi possível observar a tendência à otimização dos resultados dos modelos anteriores. Essencialmente, as métricas RMSE e R^2 apresentaram-se com 9.71 e 69.5%, respectivamente, indicando um avanço na utilização desse modelo em relação às regressões.

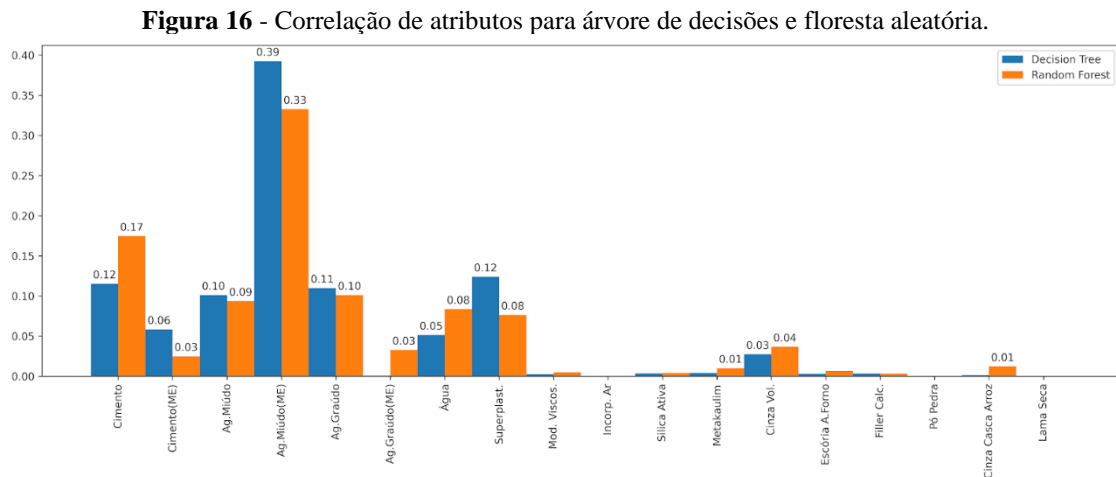
Já para a floresta aleatória, é possível observar uma maior adequação dos valores previstos com os valores verdadeiros, presentes no banco de dados. A Figura 15 mostra a previsão da resistência através da floresta aleatória.

Figura 15 - Previsão da resistência à compressão através da floresta aleatória



Fonte: Autor, 2022.

Para esse modelo, são observados os valores de RMSE e R^2 equivalentes a 7.01 e 84.1%, respectivamente. Com respeito a árvore de decisões e a floresta aleatória, a Figura 16 mostra a correlação dos insumos com a resistência à compressão do concreto através desses dois modelos.




Fonte: Autor, 2022.

Através da Figura 16, é possível observar uma maior correlação entre a massa específica do agregado miúdo e a resistência à compressão para os dois modelos em análise, equivalentes a 0.39 e a 0.33, para a árvore de decisões e floresta aleatória, respectivamente. No entanto, sendo também observada a correlação entre a resistência à compressão com o cimento (0.12 e 0.17, para a árvore de decisões e floresta aleatória, respectivamente) e o agregado graúdo (0.10 e 0.09, para a árvore de decisões e floresta aleatória, respectivamente).

Percebe-se que para os dois modelos, a correlação do consumo de aditivo superplastificante com a resistência à compressão é evidenciada (0.12 e 0.08, para a árvore de decisões e floresta aleatória, respectivamente), ao passo que para os demais aditivos, apresentam baixos coeficientes. Com respeito às adições, percebe-se maior correlação entre a cinza volante e a resistência à compressão (0.03 e 0.04, para a árvore de decisões e floresta aleatória, respectivamente) ao passo que as demais adições apresentam também baixa correlação.

De forma geral, as métricas de avaliação são apresentadas para os cinco modelos na Figura 17.

Figura 17 - Métricas de avaliação para os cinco modelos de regressão utilizados.

Fonte: Autor, 2022.

Com a Figura 17, apresentam-se as diferentes métricas de avaliação para os cinco modelos implementados. Dentre eles, o que apresentou valores mais adequados na previsão da resistência à compressão foi a floresta aleatória, com valor para RMSE e R^2 equivalentes a 7.01 e 84.1%, respectivamente, indicando a confiabilidade do modelo utilizado.

No entanto, a regressão de Lasso apresentou a menor correlação entre os modelos analisados, com valores para RMSE e R^2 equivalentes a 10.89 e 61.6%, respectivamente, representando, assim, o modelo com menor capacidade de previsão da resistência entre os analisados.

O modelo simplificado da rede neural (Regressor de MLP) apresentou os valores médios de 9,97 de RMSE, com o valor de R^2 0,64, abaixo da média geral dos demais modelos. Essas observações evidenciam que não necessariamente modelos mais robustos como rede neural, a depender das quantidades obtidas, são necessariamente mais eficientes em prever problemas dessa natureza, podendo ser expresso modelos com precisão melhor através de modelagens mais simplificadas. O resumo geral das métricas RMSE e R^2 com os respectivos desvios padrões são apresentados na Tabela 6.

Tabela 6 - Resumo das métricas RMSE e R² dos modelos analisados.

Modelo	RMSE	Desvio Padrão RMSE	R ²	Desvio Padrão R ²
Regressão Linear	9.970333	0.809377	0.666224	0.069811
Regressão Lasso	10.994743	0.878557	0.599113	0.050817
Regressão Ridge	9.970267	0.808178	0.666381	0.068864
Regressor MLP	9.970333	0.809377	0.645504	0.077623
Regressor Polinomial	10.588190	7.193257	0.397992	2.504918

Fonte: Autor, 2022.

O Regressor Polinomial, apresentou valores aproximados de RMSE 10,58 e 0,39 para o coeficiente de determinação R², bem abaixo dos valores apresentados pelos outros modelos, que indica que os valores previstos não são representados pelo modelo linear, apresentando uma baixa confiabilidade de previsão.

3.3 Gasto Computacional dos Modelos

Na análise dos modelos, tendo em vista que se trata de metodologias computacionais, devemos também considerar a aplicabilidade e a exigência de processamento desses modelos. Após a verificação de precisão através de métricas estatísticas, podemos verificar também a viabilidade de modelos mais simples para a obtenção de resultados semelhantes ou equivalentes.

Como um parâmetro extra de comparação, foi avaliado também o tempo de processamento de cada modelos, de forma a comparar o gasto computacional que cada um exige para sua implementação. Os tempos analisados foram o tempo de treinamento do modelo, e o tempo de predição, conforme Tabela 7.

Tabela 7 - Tempo apresentado para o processamento de cada modelo para treinamento e predição da variável objeto.

Modelo	Tempo de treinamento (s)	Desvio Padrão de Treinamento	Tempo médio de predição (s)	Desvio Padrão de Predição
Regressão Linear	0,000989	0,001226	0,000112486	0,000033
Regressão Lasso	0,000641	0,000103	0,000092	0,000002
Regressão Ridge	0,000562	0,000165	0,000077	0,000002

Modelo	Tempo de treinamento (s)	Desvio Padrão de Treinamento	Tempo médio de predição (s)	Desvio Padrão de Predição
Regressão MLP	48,2685	4,343212	0,008522	0,0002730
Regressão Polinomial	0,010327	0,004451	0,001339	0,002521

Fonte: Autor, 2022.

Podemos observar que o modelo mais robusto, que seria o MLP, apresentou um tempo consideravelmente maior para treinamento, tendo em vista que se trata de uma rede neural artificial, e os modelos lineares com tempos mínimos. Apesar da diferença apresentada para o treinamento, o tempo de predição se mantiveram similares para todos os modelos testados, onde o modelo de regressão de Ridge apresentou menor tempo.

4 CONCLUSÃO

Os métodos de dosagem de concretos atuais, sejam eles autoadensáveis (CAA) ou não, ainda são dependentes de grande número de tentativas e erros, validações e testes em laboratório. Uma estimativa inicial de traço, ou dosagem inicial, melhor executada pode encurtar esse laborioso processo.

Este trabalho analisou o desempenho de diferentes modelos, incluindo de inteligência artificial (linear, *Decision Tree*, *Random Forest*, *MLP* e *Regressor Polinomial*), buscando ajustar ferramentas de previsão de resistência à compressão de CAA a partir de sua composição. Os modelos foram considerados por critérios de demanda computacional, como modelos relativamente simples, com a análise de dados oriundos de um banco de dados construído através de publicações datadas entre 2001 e 2020.

Tais modelos obtiveram margem de confiabilidade de 65,8 a 83,5%, com base no escore padrão, e a mesma tendência de minimização da taxa de erros ocorreu nas demais métricas, de 10,89 a 7,35 no RMSE e 8,60 a 4,90 no MAE.

A análise estatística exploratória inicial correlacionou os dados que possuem sentido físico nas propriedades observados no processo de dosagem (Figuras 2 e 3), como a influência do fator água-cimento na resistência, relação de consumo dos agregados, contribuição para o aumento da resistência dos materiais pozolânicos, dentre outros. Esse ponto indica uma forte viabilidade para adoção de modelos de aprendizado mais robustos, pela forte evidência de correlação, pois até modelos mais simples possuem métricas satisfatórias a depender dos parâmetros requeridos.

Analisando as correlações dos insumos básicos do concreto e a resistência à compressão, foi observada uma maior correlação positiva entre o cimento e o agregado graúdo com a resistência à compressão equivalente à 0,36 e 0,13, respectivamente, e uma alta correlação negativa, entre o consumo de água e agregado miúdo, com -0,19 e -0,20, respectivamente. Em relação aos aditivos e adições, foi observada uma maior correlação positiva com a resistência à compressão com o superplastificante (0,25) e da escória granulada de alto forno (0,25)

Na análise dos modelos para a estimativa da resistência à compressão com base nos insumos analisados, dentre os modelos treinados, o que apresentou valores de métricas de avaliação superiores em relação aos demais modelos, foi a floresta aleatória, com RMSE equivalente à 7,01 e R^2 equivalente a 84.1%, apresentando evidência que o modelo pode ser adequado para a predição da resistência à compressão.

Portanto, a análise estatística permitiu a correlação entre os parâmetros componentes do concreto, assim como os modelos estudados, em especial a floresta aleatória, permitiu, de modo satisfatório, estimar a resistência à compressão do concreto com base nos insumos pré-definidos através de trabalhos anteriores componentes do banco de dados.

O Regressor Polinomial, apesar de ser uma regressão linear, no sentido linear nos parâmetros, possui um alto desvio padrão se comparado à média dos demais, o que pode indicar uma baixa capacidade de predição e elevada variabilidade das medidas previstas em comparação com as reais. A partir dessa análise inicial pretende-se investigar modelos mais complexos em trabalhos futuros.

Em linhas gerais podemos destacar os principais pontos observados:

i) A correlação de Pearson é eficiente em evidenciar os comportamentos físicos entre os materiais durante o processo de dosagem.

ii) Foi observado estatisticamente que aditivos que possuem aparente efeito pozolânico na resistência, podem ser prejudiciais para o processo de dosagem em geral, conforme é possível visualizar no *heatmap* dos aditivos e adições, quanto ao material Cinza da Casca de Arroz, versus resistência.

iii) Modelos mais simplificados, desde modelos lineares, podem prever com precisão superior a 80%, e desvios de 5% em média, a resistência à compressão dos concretos estudados. Aplicando modelos estatísticos de ajuste, o valor de predição poderia ser previsto com precisão superior a 95% apenas com ajuste da resistência requerida, similar ao processo de fck e fc expressos na NBR 6118.

iv) Implementações de redes neurais e outros modelos mais robustos não necessariamente implicam em previsões mais precisas, conforme foi visualizado na tabela de RMSE e desvio padrão.

v) Dentre os modelos analisados os modelos lineares simples e o de Ridge obtiveram melhores performances com menores desvio padrão, na casa de 0,66 e 0,06 respectivamente. Logo essa contribuição expressa o resumo da investigação de modelos mais simples para implementações de aprendizado de máquina evidenciando que, para esse caso, modelos mais simples, performam melhor que modelos mais robustos

REFERÊNCIAS

- ABREU, A. G. DE. **Efeito das adições minerais na resistividade elétrica de concretos convencionais**. Dissertação (Mestrado em Engenharia Civil) - Escola de Engenharia da Universidade Federal do Rio Grande do Sul. Porto Alegre, p. 142. 1998.
- ABU YAMAN, M.; ABD ELATY, M.; TAMAN, M. Predicting the ingredients of self compacting concrete using artificial neural network. **Alexandria Engineering Journal**, v. 56, n. 4, p. 523–532, 2017.
- ADAM, B.; SMITH, I. F. Reinforcement Learning for Structural Control. **Journal of Computing in Civil Engineering**, v. 22, n. 2, p. 133–139, 2008.
- DINIZ, H. A. A.; OLIVEIRA, J. N.; SILVA, L. P.; MACÊDO, M. S.; SOUZA, M. M. Caracterização E Avaliação Das Propriedades De Concretos Autoadensáveis Com Adições Minerais E Baixo Consumo De Cimento. **Holos**, v. 5, p. 51–64, 2018.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 15823-1 : Concreto autoadensável Parte 1: Classificação, controle e recebimento no estado fresco. 2 ed. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2017. 20 p.
- BASU, P.; GUPTA, R. C.; AGRAWAL, V. Effects of sandstone slurry, the dosage of superplasticizer and water/binder ratio on the fresh properties and compressive strength of self-compacting concrete. **Materials Today: Proceedings**, v. 21, p. 1250–1254, 2020.
- DOUMA, Omar Belalia; BOUKHATEM, Bakhta; GHRICI, Mohamed; TAGNIT-HAMOU, Arezki. Prediction of properties of self-compacting concrete containing fly ash using artificial neural network. **Neural Computing And Applications**, [S.L.], v. 28, n. 1, p. 707-718, 7 jun. 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00521-016-2368-7>.
- BENAICHA, M.; ALAOU, A. H.; JALBAUD, O.; BURTSCHHELL, Y. Dosage effect of superplasticizer on self-compacting concrete: Correlation between rheology and strength. **Journal of Materials Research and Technology**, v. 8, n. 2, p. 2063–2069, 2019.
- BHATTACHARYA, B.; SOLOMATINE, D. P. Machine learning in soil classification. **Neural Networks**, v. 19, n. 2, p. 186–195, 2006.
- BINGÖL, A. F.; TOHUMCU, I. Effects of different curing regimes on the compressive strength properties of self compacting concrete incorporating fly ash and silica fume. **Materials and Design**, v. 51, p. 12–18, 2013.
- BIXAPATHI, Guguloth; SARAVANAN, M. Strength and durability of concrete using Rice Husk ash as a partial replacement of cement. **Materials Today: Proceedings. Telangana, India**. <https://doi.org/10.1016/j.matpr.2021.11.267>
- BOEL, V; AUDENAERT, K; DE SCHUTTER, G; HEIRMAN, G; VANDEWALLE, L; DESMET, B; VANTOMME, J. Transport properties of self compacting concrete with limestone filler or fly ash. **Materials and Structures/Materiaux et Constructions**, v. 40, n. 5, p. 507–516, 2007.

BORKOWSKI, A. Using Artificial Intelligence for COVID-19 Chest X-ray Diagnosis. **Federal Practitioner**, v. 19, n. Vol 37 No 9, p. 398–404, 2020.

BOUZOUBAË, N.; LACHEMI, M. Self-compacting concrete incorporating high volumes of class F fly ash: Preliminary results. **Cement and Concrete Research**, v. 31, n. 3, p. 413–420, 2001.

CARVALHO, André Ponce de Leon F. de. **Redes Neurais Artificiais**, c2009. Página inicial. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Acesso em: 30 de jan. de 2022.

CHENG, Chongsheng; SHEN, Zhigang. Semi real-time detection of subsurface consolidation defects during concrete curing stage. *Construction And Building Materials*, Lincoln, v. 270, p. 1-14, fev. 2021.

CONGRO, M; MONTEIRO, V. M. de A; BRANDÃO, A. L. T; SANTOS, B. F; ROEHL, D. Prediction of the residual flexural strength of fiber reinforced concrete using artificial neural networks. **Construction And Building Materials**, [S.L.], v. 303, p. 124502, out. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2021.124502>.

COSTA, A. C. S. DE S.; CABRAL, A. E. B. Estudo comparativo entre o concreto autoadensável e o concreto convencional vibrado em obra vertical. **Ambiente Construído**, v. 19, n. 4, p. 289–301, 2019.

COUTO, C; ALMEIDA, J. A; PINTO, J. D. S; BAMBERG, P; STARLING, T. Influência da Pozolanicidade da Escória de Alto-forno nas Propriedades de Argamassas e Concretos Duráveis. **Construindo**, Belo Horizonte, v.2, n.1, p.31-34, jan./jun. 2010.

DOMONE, A. P. The Slump Flow Test for High-Workability Concrete. **Cement and Concrete Research**, v.28, n2, p.177-182, fev.1998. [https://doi.org/10.1016/S0008-8846\(97\)00224-X](https://doi.org/10.1016/S0008-8846(97)00224-X)

ELMASRI, Ramez; NAVATHE, Shamkant B. **Fundamentals of Database Systems**. 7. ed. New Jersey: Pearson Higher Education, 2015. 1280 p.

ENTEZAMI, A.; SHARIATMADAR, H.; MARIANI, S. Fast unsupervised learning methods for structural health monitoring with large vibration data from dense sensor networks. **Structural Health Monitoring**, v. 19, n. 6, p. 1685–1710, 2020.

ENTEZAMI, A.; SHARIATMADAR, H.; SARMADI, H. Condition Assessment of Civil Structures for Structural Health Monitoring Using Supervised Learning Classification Methods. **Iranian Journal of Science and Technology - Transactions of Civil Engineering**, v. 44, n. s1, p. 51–66, 2020.

FENG, D. C; LIU, Z. T; WANG, X. D; CHEN, Y; CHANG, J. Q; WEI, D. F; JIANG, Z. M; Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. **Construction and Building Materials**, v. 230, p. 117000, 2020.

FERREIRA, L.; RIBEIRO, F. Estudo Comparativo do Concreto Auto Adensável com Cinza da Casca de Arroz sem Controle de Queima e Sílica Ativa. **Paranoá: cadernos de arquitetura e urbanismo**, n. 20, p. 1–12, 2018.

FILHO, F. M. A.; BARRAGÁN, B.E.; CASAS, J.R.; EL DEBS, A. L. H. C. Variabilidade da aderência e das propriedades mecânicas do concreto auto-adensável. **Revista IBRACON de Estruturas e Materiais**, v. 1, n. 1, p. 31–57, 2008.

GOWRIPALAN, Nadarajah; SHAKOR, Pshtiwan; ROCKER, Paul. Pressure exerted on formwork by sel-compacting concrete at early ages: A review. **Case Studies In Construction Materials**, [s. l.], v. 15, p. 1-21, dez. 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214509521001571?via%3Dihub>. Acesso em: 01 dez. 2021.

GÜNEYISI, E.; GESOLU, M.; ÖZBAY, E. Strength and drying shrinkage properties of self-compacting concretes incorporating multi-system blended mineral admixtures. **Construction and Building Materials**, v. 24, n. 10, p. 1878–1887, 2010.

IKUMI, T; GALEOTE, E; PUJADAS, P; FUENTE, A; LÓPEZ-CARREÑO, R. D. Neural network-aided prediction of post-cracking tensile strength of fibre-reinforced concrete. **Computers & Structures**, [S.L.], v. 256, p. 106640, nov. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compstruc.2021.106640>.

JALAL, M.; MANSOURI, E. Effects of fly ash and cement content on rheological, mechanical, and transport properties of high-performance self-compacting concrete. **Science and Engineering of Composite Materials**, v. 19, n. 4, p. 393–405, 2012.

KONERU, V. S.; GHORPADE, V. G. Assessment of strength characteristics for experimental based workable self compacting concrete using artificial neural network. **Materials Today: Proceedings**, v. 26, n. xxxx, p. 1238–1244, 2019.

KUMAR, S.P. Leo. State of The Art-Intense Review on Artificial Intelligence Systems Application in Process Planning and Manufacturing. **Engineering Applications Of Artificial Intelligence**, [S.L.], v. 65, p. 294-329, out. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.engappai.2017.08.005>.

LY, H. B; NGUYEN, T. A; MAI, H. V. T; TRAN, V. Q. Development of deep neural network model to predict the compressive strength of rubber concrete. **Construction And Building Materials**, [S.L.], v. 301, p. 124081, set. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2021.124081>.

MEHTA, Povindar Kumar; MONTEIRO, Paulo J. M. **Concreto: Microestrutura, Propriedades e Materiais**. 3. ed. São Paulo: Ibracon - Instituto Brasileiro de Concreto, 2008.

MONTEIRO, Paulo J. M.; MILLER, Sabbie A.; HORVATH, Arpad. Towards sustainable concrete. **Nature Materials**, [S.L.], v. 16, n. 7, p. 698-699, 27 jun. 2017. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/nmat4930>.

NEHDI, M.; PARDHAN, M.; KOSHOWSKI, S. Durability of self-consolidating concrete incorporating high-volume replacement composite cements. **Cement and Concrete Research**, v. 34, n. 11, p. 2103–2112, 2004.

NHAT-DUC, H.; NGUYEN, Q. L.; TRAN, V. D. Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network. **Automation in Construction**, v. 94, n. June, p. 203–213, 2018.

PAZ, K. B; ALENCAR, J. P; ALMEIDA, L. C; LIMA, C. L. F. A; GOMES, J. P. P; SOARES, J. B. Identificação de Defeitos do Tipo "Panela" em Pavimento Asfáltico por Meio de Redes Neurais Convolucionais. 34º Congresso de Pesquisa e Ensino em Transporte da Anpet, Online, v. 34, n. 4, p. 863-874, nov. 2020. Disponível em: http://www.anpet.org.br/anais34/documentos/2020/Infraestrutura/Dimensionamento,%20Avalia%C3%A7%C3%A3o%20e%20Gest%C3%A3o%20de%20Pavimentos%20I/8_387_AC.pdf. Acesso em: 27 nov. 2021.

PHAM, B. T. SON, L. H; HOANG, T. A; NGUYEN, D. M; BUI, D. T. Prediction of shear strength of soft soil using machine learning methods. **Catena**, v. 166, n. April, p. 181–191, 2018.

PROMSAWAT, Pongsakon; CHATVEERA, Burachat; SUA-IAM, Gritsada; MAKUL, Natt. Properties of self-compacting concrete prepared with ternary Portland cement-high volume fly ash-calcium carbonate blends. *Case Studies In Construction Materials*, Thailand, v. 13, p. 1-17, dez. 2020.

RAMANATHAN, P; BASKAR, I; MUTHUPRIYA, P; VENKATASUBRAMANI, R. Performance of self-compacting concrete containing different mineral admixtures. **KSCE Journal of Civil Engineering**, v. 17, n. 2, p. 465–472, 2013.

RYMAN-TUBB, N. F.; KRAUSE, P.; GARN, W. How Artificial Intelligence and machine learning research impacts payment card fraud detection: A survey and industry benchmark. **Engineering Applications of Artificial Intelligence**, v. 76, n. June, p. 130–157, 2018.

SADATI, S; SILVA, L. E. B; WUNSCH II, D. C; KHAYAT, K. H. Artificial Intelligence to Investigate Modulus of Elasticity of Recycled Aggregate Concrete. **ACI Materials Journal**, v. 116, n. 1, p. 51–62, 2019.

SALMAN, F. M; ABU-NASER, S. S; ALAJRAM, E; ABU-NASSER, B. S; ASHQAR, L. A. M. COVID-19 Detection using Artificial Intelligence. **International Journal of Academic Engineering Research**, v. 4, n. 3, p. 18–25, 2020.

SARMADI, H.; ENTEZAMI, A. Application of supervised learning to validation of damage detection. **Archive of Applied Mechanics**, v. 91, n. 1, p. 393–410, 2021.

SHI, C; WU, Z; LV, K; WU, L. A review on mixture design methods for self-compacting concrete. **Construction and Building Materials**, v. 84, p. 387–398, 2015.

STORME, T.; DERUDDER, B.; DÖRRY, S. Introducing cluster heatmaps to explore city/firm interactions in world cities. *Computers, Environment And Urban Systems*, v. 76, n. 00, p. 57-68, jul. 2019.

SUKUMAR, B.; NAGAMANI, K.; SRINIVASA RAGHAVAN, R. Evaluation of strength at early ages of self-compacting concrete with high volume fly ash. **Construction and Building Materials**, v. 22, n. 7, p. 1394–1401, 2008.

SUN, L; SHANG, Z; XIA, Y; BHOWMICK, S. Review of Bridge Structural Health Monitoring Aided by Big Data and Artificial Intelligence: From Condition Assessment to Damage Detection. **Journal of Structural Engineering**, v. 146, n. 5, p. 04020073, 2020.

TUTIKIAN, B. F. **Método para dosagem de concreto autoadensável**. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Rio Grande do Sul. Porto Alegre, p. 149. 2004.

VAN DAO, D; LY, H. B; TRINH, S. H; LE, T. T; PHAM, B. T. Artificial intelligence approaches for prediction of compressive strength of geopolymer concrete. **Materials**, v. 12, n. 6, 2019.

Wang SC. (2003) Artificial Neural Network. In: Interdisciplinary Computing in Java Programming. **The Springer International Series in Engineering and Computer Science**, vol 743. Springer, Boston, MA. https://doi.org/10.1007/978-1-4615-0377-4_5

WANG, Zifei; MAN, Yi. Artificial intelligence algorithm application in wastewater treatment plants: case study for cod load prediction. **Applications Of Artificial Intelligence In Process Systems Engineering**, [S.L.], p. 143-164, 2021. Elsevier. <http://dx.doi.org/10.1016/b978-0-12-821092-5.00009-7>.

YAZICI, Y. Approaches to Fraud Detection on Credit Card Transactions using Artificial Intelligence Methods. **Machine Learning**, p. 235–244, 2020.

APÊNDICE 1 – RECORTE DO BANCO DE DADOS INICIAL

Tabela 1 - Recorte do banco de dados com dados de consumo dos insumos básicos.

Entrada	Consumo Insumos Básicos								Fator A/C
	Caracterização Cimento			Caracterização Miúdo		Caracterização Graúdo		Água (Kg/m ³)	
	Cimento (Kg/m ³)	Resistência Nominal (28d/MPa)	Massa Específica (Kg/m ³)	Miúdo (Kg/m ³)	Massa Específica (Kg/m ³)	Graúdo (Kg/m ³)	Massa Específica (Kg/m ³)		
0	380,00	-	3120	945,56	2650	773,64	2850	-	0,61
1	360,00	-	3120	963,92	2650	780,48	2850	-	0,61
2	380,00	-	3120	943,47	2650	771,93	2850	-	0,62
3	360,00	-	3120	951,94	2650	778,86	2850	-	0,62
4	389,50	-	3120	939,03	2650	768,30	2850	-	0,60
5	369,00	-	3120	947,49	2650	775,22	2850	-	0,60
				...					
502	225,00	57,2	3140	908	2490	652	2680	-	0,78

Fonte: Autor, 2022.

Tabela 2 - Recorte do banco de dados com dados de consumo dos aditivos.

Entrada	Consumo de Aditivos												
	Super Plastificante (%)	Modificador de Viscosidade (Kg/m ³)	Incorporador de Ar (Kg/m ³)	Sílica Ativa (Kg/m ³)	Micro-sílica (%)	Metacaulin (%)	Cinza Volante (%)	Cinzas Volantes (Kg/m ³)	Escória de alto forno (Kg/m ³)	Filer Calcário (Kg/m ³)	Pó de Pedra (Kg/m ³)	Cinza de casca de Arroz (Kg/m ³)	Lama seca de Arenito (Kg/m ³)
0	-	-	-	-	5	-	-	-	-	-	-	-	-
1	-	-	-	-	10	-	-	-	-	-	-	-	-
2	-	-	-	-	-	5	-	-	-	-	-	-	-
3	-	-	-	-	-	10	-	-	-	-	-	-	-
4	-	-	-	-	5	-	-	-	-	-	-	-	-
5	-	-	-	-	10	-	-	-	-	-	-	-	-
						...							
502	7,5	-	-	-	-	-	-	275	-	-	-	-	-

Fonte: Autor, 2022.

Tabela 3 – Recorte do banco de dados com dados de Caracterização das Resistências.

Caracterização das Resistências							
Entrada	Compressão		Tração		Flexão		Módulo de Elasticidade (GPa) x 10 ⁻³
	Resistência à Compressão (MPa)	Idade (dias)	Resistência à Tração (MPa)	Idade (dias)	Resistência à Flexão (MPa)	Idade (dias)	
0	26,65	28	2,89	28	-	-	-
1	27,99	28	2,95	28	-	-	-
2	26,61	28	2,86	28	-	-	-
3	26,63	28	2,93	28	-	-	-
4	26,89	28	2,96	28	-	-	-
5	28,21	28	2,99	28	-	-	-
				...			
502	32	28	-	-	-	-	-

Fonte: Autor, 2022.

APÊNDICE 2 – RECORTE DO BANCO DE DADOS ORGANIZADO PARA O PRÉ-PROCESSAMENTO

Tabela 1 - Recorte Banco de dados com informações do consumo de insumos básicos (início do pré-processamento)

ind ex	bm_cement_consumption	bm_cement_specific_mass	bm_fine_aggregate_consumption	bm_fine_aggregate_specific_mass	bm_coarse_aggregate_consumption	bm_coarse_aggregate_specific_mass	bm_water_consumption
0	380.00	3120.00	945.56	2650.00	773.64	2850.00	231.80
1	360.00	3120.00	953.92	2650.00	780.48	2850.00	219.60
2	380.00	3120.00	943.47	2650.00	771.93	2850.00	235.60
3	360.00	3120.00	951.94	2650.00	778.86	2850.00	223.20
4	389.50	3120.00	939.03	2650.00	768.30	2850.00	233.70
5	369.00	3120.00	947.49	2650.00	775.22	2850.00	221.40
				...			
502	225.00	3140.00	908.00	249.00	652.00	2680.00	175.50

Fonte: Autor, 2022.

Tabela 2 - Recorte do banco de dados com dados de consumo dos aditivos (início do pré-processamento)

ind ex	am_superplas ticizer	am_viscosity_ modifier	am_air_entr aining	am_silica_ fume	am_limestone _filler	am_stone _dust	am_fly _ash	am_blast_furna nce_slag	am_rice_hus ch_ash	am_dry_sandsto ne_mud
0	0.00	0.00	0.00	19.00	0.00	0.00	0.00	0.00	0.00	0.00
1	0.00	0.00	0.00	36.00	0.00	0.00	0.00	0.00	0.00	0.00
2	0.00	0.00	0.00	0.00	0.00	5.00	0.00	0.00	0.00	0.00
3	0.00	0.00	0.00	0.00	0.00	10.00	0.00	0.00	0.00	0.00
4	0.00	0.00	0.00	19.48	0.00	0.00	0.00	0.00	0.00	0.00
5	0.00	0.00	0.00	36.90	0.00	0.00	0.00	0.00	0.00	0.00
					...					
502	16.88	0.00	0.00	0.00	0.00	0.00	275.00	0.00	0.00	0.00

Fonte: Autor, 2022.

Tabela 3- Recorte do banco de dados com dados de Caracterização das Resistências. (início pré-processamento)

Index	strength_compression
0	26.65
1	27.99
2	26.61
3	26.63
4	26.89
5	28.21
	...
502	32.00

Fonte: Autor, 2022.