



**PREVISÃO DA RESISTÊNCIA À COMPRESSÃO DO CONCRETO  
CONVENCIONAL BRASILEIRO BASEADO EM MACHINE  
LEARNING: UM ESTUDO COMPARATIVO ENTRE BASES DE DADOS**

**VITOR PEREIRA SILVA**

DISSERTAÇÃO DE MESTRADO DO PROGRAMA DE PÓS-GRADUAÇÃO  
EM ESTRUTURAS E CONSTRUÇÃO CIVIL

**UNIVERSIDADE DE BRASÍLIA**

**FACULDADE DE TECNOLOGIA**

**DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÃO DA RESISTÊNCIA À COMPRESSÃO DO CONCRETO  
CONVENCIONAL BRASILEIRO BASEADO EM MACHINE  
LEARNING: UM ESTUDO COMPARATIVO ENTRE BASES DE  
DADOS**

**VITOR PEREIRA SILVA**

**ORIENTADOR: JOÃO HENRIQUE DA SILVA RÊGO**

**COORIENTADOR: FRANCISCO EVANGELISTA JÚNIOR**

**DISSERTAÇÃO DE MESTRADO EM ESTRUTURAS E CONSTRUÇÃO CIVIL**

**BRASÍLIA/DF – AGOSTO/2023**

**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÃO DA RESISTÊNCIA À COMPRESSÃO DO CONCRETO  
CONVENCIONAL BRASILEIRO BASEADO EM MACHINE LEARNING: UM  
ESTUDO COMPARATIVO ENTRE BASES DE DADOS**

**VITOR PEREIRA SILVA**

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ESTRUTURAS E CONSTRUÇÃO CIVIL.

APROVADA POR:

---

Prof. João Henrique da Silva Rêgo, Dr. (ENC - UnB)  
(Orientador)

---

Prof. Francisco Evangelista Júnior, Dr. (ENC - UnB)  
(Coorientador)

---

Profa. Michelle Tereza Marques Carvalho, Dra. (ENC - UnB)  
(Examinadora interna)

---

Prof. Julliana Simas Vasconcellos, Dra. (IACT - UEG)  
(Examinador externo)

BRASÍLIA/DF – AGOSTO/2023

## FICHA CATALOGRÁFICA

SILVA, VITOR PEREIRA

Previsão da resistência à compressão do concreto convencional brasileiro baseado em Machine Learning: um estudo comparativo entre bases de dados. [Distrito Federal] 2023. XXIII, 116p., 210x297 mm (ENC/FT/UnB, Mestre em Estruturas e Construção Civil, 2023).  
Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia. Departamento de Engenharia Civil e Ambiental.

- |                             |                            |
|-----------------------------|----------------------------|
| 1. Resistência à compressão | 2. Inteligência artificial |
| 3. Concreto                 | 4. Modelo preditivo        |
| 5. Machine Learning         | 6. Base de dados           |
| I. ENC/FT/UnB               | II. Título (Mestre)        |

## REFERÊNCIA BIBLIOGRÁFICA

SILVA, V. P. (2023). Previsão da resistência à compressão do concreto convencional brasileiro baseado em Machine Learning: um estudo comparativo entre bases de dados. Dissertação de Mestrado em Estruturas e Construção Civil, Publicação E.DM – 00A/23, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 116p.

## CESSÃO DE DIREITOS

AUTOR: Vitor Pereira Silva

TÍTULO: Previsão da resistência à compressão do concreto convencional brasileiro baseado em Machine Learning: um estudo comparativo entre bases de dados.

GRAU: Mestre ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito.

---

Vitor Pereira Silva

UnB, Campus Darcy Ribeiro, Asa Norte

70.904-111 Brasília/DF – Brasil

victorpereira.\_14@hotmail.com

## **DEDICATÓRIA**

Dedico este estudo à minha família e a Deus.

*“A persistência é o caminho do êxito.  
A coragem não é ausência do medo; é a persistência apesar do medo”*

**Mark Twain, Nelson Mandela e Ambrose H.**

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, pela determinação de continuar a viver com alegria cada dia e atingir meus objetivos durante o caminho.

Aos meus pais Celismar José da Silva e Edna Aparecida Pereira Silva, por sempre me apoiarem nas minhas escolhas durante a vida, pelo trabalho contínuo e longo para conseguir arcar financeiramente com as despesas financeiras. À minha irmã, Helen Kássia Pereira Silva por estar sempre ao meu lado me proporcionando irmandade, amor e amizade em todos os momentos. À minha avó Maria Soares pelo amor, proteção e orações sempre.

Ao meu namorado, Paulo Henrique Ramos de Oliveira Machado, por ser meu maior suporte, pelo companheirismo, apoio, paciência, por seu amor e por sempre acreditar em mim, essa conquista também é dele por tudo que fez e faz por mim.

Aos meus amigos de longa duração, pela amizade, irmandade e companheirismo durante tantos anos. Aos meus amigos Válter Junior, Beatriz Campos, Carla Falcão, Géssika Santiago, Laryssa Feitosa, Amanda Arciprett, Mirian Costa e Geovana Rafaela pela amizade, suporte diante de todas as situações boas e ruins da vida e toda confiança depositada.

Ao meu orientador, João Henrique da Silva Rêgo, que tem me auxiliado desde o início, desde a escolha das disciplinas durante o primeiro ano do mestrado até a finalização da pesquisa. Ele sempre esteve à disposição para me ajudar durante a pesquisa e discutir sobre este trabalho, dando um suporte essencial para sua conclusão, sendo lendo e relendo as diversas versões preliminares dos artigos e da dissertação até sua versão final. Ao meu coorientador, Francisco Evangelista Júnior, por estar disposto a fazer parceria na área de métodos matemática aplicados a engenharia e auxiliar em todas as etapas de modelagem e treinamento na área de Inteligência Artificial, me proporcionando novos aprendizados.

Aos professores do PECC, que com intensa dedicação participaram da minha formação científica e transmitiram seus conhecimentos, que levarei comigo para a vida.

Aos amigos que conheci no mestrado e com quem compartilhei experiências, em especial Maykon Viera, Melissa, Matheus e Lucas Vasques, que me ajudaram e deram suporte durante minha jornada.

Aos trabalhadores do PECC, por manterem o ambiente de estudo limpo e organizado, e pela simpatia durante os dias árdios.

À Fundação de Apoio a Pesquisa do Distrito Federal (FAP-DF) pelos apoios financeiros para a realização de pesquisas no Programa de Pós-graduação em Estruturas e Construção Civil da Universidade de Brasília (PECC/UnB), junto com o Decanato de Pós-Graduação (DPG/UnB). A todas as pessoas que, direta ou indiretamente, contribuíram para a elaboração da presente Dissertação de Mestrado. Por fim, não menos importante, à todas as minhas famílias pelo apoio e carinho

## RESUMO

### PREVISÃO DA RESISTÊNCIA À COMPRESSÃO DO CONCRETO CONVENCIONAL BRASILEIRO BASEADO EM MACHINE LEARNING: UM ESTUDO COMPARATIVO ENTRE BASES DE DADOS

Recentemente, várias técnicas de aprendizado de máquina (ML) estão surgindo como formas alternativas e eficientes de prever como os componentes influenciam as propriedades da mistura final. Na área da engenharia civil, pesquisas recentes já utilizam técnicas de ML em relação às dosagens convencionais de concreto. A importância de discutir seu uso aplicando-se dados brasileiros está inserida em um contexto internacional no qual essa metodologia já está sendo aplicada, sendo necessário verificar o uso dessas técnicas com bancos de dados nacionais ou com o que é criado a partir de dados de entrada nacionais. Nesta pesquisa, uma dessas técnicas, uma rede neural artificial (ANN), é utilizada para determinar a resistência à compressão do concreto convencional brasileiro, utilizando um banco de dados construído por meio de publicações em congressos e trabalhos acadêmicos e comparando-o com o banco de dados internacional em várias idades. A nova base de dados brasileira é de extrema relevância uma vez que contribui com mais dados sobre traços de concreto e permite sua pesquisa para diversas aplicações. Os dados foram organizados em nove variáveis e cinco casos diferentes, nos quais as amostras de dados usadas para treinamento e teste variam. As oito variáveis de entrada possíveis foram: consumo de cimento, escória de alto-forno, pozolana, água, aditivo, agregado miúdo, agregado graúdo e idade. Conseqüentemente, a variável de resposta foi a resistência à compressão do concreto. Utilizar dados internacionais como conjunto de treinamento e dados brasileiros como conjunto de teste, ou vice-versa, não mostrou resultados satisfatórios isoladamente. Os resultados mostraram uma variação nos cinco cenários; no entanto, ao usar o banco de dados brasileiro e o de referência juntos como conjuntos de teste e treinamento, obteve-se um  $R^2$  de 0,97 e um  $R^2$  de 0,86, mostrando que, na união dos dois bancos de dados, um bom modelo preditivo é obtido.

**Palavras-chave:** resistência à compressão, concreto, machine learning, inteligência artificial, modelo preditivo, base de dados.

## **ABSTRACT**

### **PREDICTION OF COMPRESSIVE STRENGTH OF BRAZILIAN CONVENTIONAL CONCRETE BASED ON MACHINE LEARNING: A COMPARATIVE STUDY AMONG DATABASES**

Recently, several machine learning (ML) techniques have emerged as alternative and efficient ways to predict how components influence the properties of the final mixture. In the field of civil engineering, recent research has already utilized ML techniques concerning conventional concrete mix designs. The importance of discussing their use in the Brazilian context is embedded in an international context where this methodology is already being applied, making it necessary to assess the applicability of these techniques with national databases or those derived from national input data. In this study, one of these techniques, an artificial neural network (ANN), is used to determine the compressive strength of Brazilian conventional concrete, using a database constructed through congress publications and academic works, and comparing it with an international database at various ages. The new Brazilian database is extremely relevant as it contributes with more data on concrete mixes and allows its search for different applications. The data were organized into nine variables and five different cases, where the data samples used for training and testing varied. The eight possible input variables were: cement content, blast furnace slag, pozzolan, water, additive, fine aggregate, coarse aggregate, and age. The response variable was the compressive strength of concrete. Using international data as the training set and Brazilian data as the test set, or vice versa, did not show satisfactory results individually. The results showed variation across the five scenarios; however, when using the Brazilian and reference databases together as training and test sets, an  $R^2$  of 0.97 and an  $R^2$  of 0.86 were obtained, demonstrating that a good predictive model is achieved by combining the two databases.

**Keywords:** compressive strength, concrete, machine learning, artificial intelligence, predictive model, dataset.

## LISTA DE FIGURAS

|  |    |
|--|----|
| Figura 1.1 Projeção da Produção de Cimento no Brasil para cenários de alta e baixa demanda de materiais.....   | 1  |
| Figura 1.2 – Número de publicações por ano no Web of Science.....  | 4  |
| Figura 2.1- Ensaio de resistência à compressão axial do concreto.....  | 7  |
| Figura 2.2 - Redução na demanda de água de amassamento devido à adição por aditivo incorporador de ar.....   | 11 |
| Figura 2.3- Relação entre resistência a compressão (MPa) e idade de ruptura nos três métodos de dosagem analisados.....  | 17 |
| Figura 2.4 Distribuição Granulométrica para diferentes mineralogias de agregados.....  | 19 |
| Figura 3.1 - Hiperplanos de separação entre classes .....  | 26 |
| Figura 3.2 - Transformação gráfica do SVM para o SVR em casos de equações não lineares   | 26 |
| Figura 3.3 – a) Um perceptron. b) Uma rede neural de multicamadas contendo vários nós semelhantes a perceptrons. Os nós que representam variáveis de entrada ( $x_1, x_2, ..$ ) são cinzas e os nós de funções de ativação ( $a_1, a_2, ...$ ) são pretos..... | 27 |
| Figura 3.4 - Esquema de Random Forest .....  | 31 |
| Figura 3.5 - Predição de valores de resistência (em $y$ ) utilizando redes neurais comparados com resultados reais testados em laboratórios (em $x$ ) em MPa.....  | 32 |
| Figura 3.6 - A relação entre as oito variáveis de entrada e a resistência à compressão do concreto no conjunto de dados bibliográficos.....  | 34 |
| Figura 4.1 - Fluxograma de pesquisa .....  | 43 |
| Figura 4.2 - Bases de dados utilizadas em cada caso para treinamento e teste .....   | 50 |
| Figura 4.3- Representação de camadas ocultas em um modelo de redes neurais. ....   | 51 |
| Figura 5.1 - Correlação de Pearson em DATA_BR23 .....  | 58 |
| Figura 5.2- Histogramas com DATA_BR23.....   | 59 |
| Figura 5.3- Correlação de Pearson em DATA_YEH98 .....  | 61 |
| Figura 5.4 - Histogramas dos inputs em DATA_YEH98.....   | 63 |
| Figura 5.5 Parâmetro $R^2$ para todos os casos.....  | 67 |
| Figura 5.6 Parâmetro RMSE em todos os casos.....   | 69 |
| Figura 5.7 Parâmetro MSE pra todos os casos. ....  | 70 |
| Figura 5.8 - Gráficos de tendências dos 5 casos.....   | 71 |
| Figura 5.9 - Fator de Importância no Caso 2 (Esquerda) e Caso 5 (direita).....   | 72 |

## LISTA DE TABELAS

|  |    |
|--|----|
| Tabela 2.1 Resumo de métodos de dosagem pra UHPC.....  | 21 |
| Tabela 3.1 Resumo de Parâmetros de Treinamento e Teste em Pesquisas Acadêmicas.....  | 38 |
| Tabela 4.1 - Inputs e Outputs .....  | 45 |
| Tabela 4.2- Valores médios adotados - NBR 16697 .....  | 47 |
| Tabela 4.3 - Acrônimos dos casos .....   | 49 |
| Tabela 4.4 - Hiperparâmetros utilizados pelo usuário.....  | 52 |
| Tabela 5.1- Dados estatísticos das duas bases de dados analisadas .....  | 57 |
| Tabela 5.2 - Resistência Prevista (MPa) para todos os casos: (Max), médios ( $\mu$ ), mínimos (Min) e desvio padrão ( $\sigma$ ) ..... | 64 |
| Tabela 5.3- Parâmetros Estatísticos.....   | 66 |
| Tabela 5.4 - Análise de Importância.....   | 72 |

## LISTA DE SÍMBOLOS, NOMENCLATURAS E ABREVIACÕES

|                |   |
|----------------|---|
| a/c            | Relação água-cimento  |
| ABNT           | Associação Brasileira de Normas Técnicas                      |
| ANN            | Redes Neurais Artificiais                                     |
| CP             | Cimento Portland  |
| CP I           | Cimento Portland Comum  |
| CP II -F       | Cimento Portland Composto com material carbonático            |
| CP II- Z       | Cimento Portland Composto com Pozolana                        |
| CP II-E        | Cimento Portland Composto com Escória Granulada de Alto-Forno |
| CP III         | Cimento Portland de Alto Forno                                |
| CP IV          | Cimento Portland Pozolânico                                   |
| CP V-ARI       | Cimento Portland de Alta Resistência Inicial                  |
| CP-S           | Cimento Portland Comum com adição                             |
| DT             | <i>Decision Trees</i>   |
| MAE            | Erro médio absoluto   |
| MSE            | Erro quadrático médio   |
| R <sup>2</sup> | Coefficiente de Determinação                                  |
| RF             | <i>Random Forest</i>  |
| RMSE           | Erro quadrático médio raiz                                    |
| UHPC           | Concreto de ultra-alto desempenho                             |

## SUMÁRIO

|            |   |           |
|------------|---|-----------|
| <b>1</b>   | <b>INTRODUÇÃO</b> .....   | <b>1</b>  |
| <b>1.1</b> | <b>IMPORTÂNCIA DO TEMA</b> .....  | <b>1</b>  |
| <b>1.2</b> | <b>MOTIVAÇÃO DA PESQUISA</b> .....  | <b>3</b>  |
| <b>1.3</b> | <b>OBJETIVOS</b> .....  | <b>4</b>  |
| 1.3.1      | <i>Objetivo geral</i> .....   | 4         |
| 1.3.2      | <i>Objetivos específicos</i> .....  | 4         |
| <b>1.4</b> | <b>ESTRUTURA DA DISSERTAÇÃO</b> .....   | <b>5</b>  |
| <b>2</b>   | <b>CONCRETOS DE CIMENTO PORTLAND</b> .....  | <b>6</b>  |
| <b>2.1</b> | <b>PROPRIEDADES DO CONCRETO NO ESTADO FRESCO</b> .....  | <b>10</b> |
| <b>2.2</b> | <b>RESISTÊNCIA À COMPRESSÃO EM CONCRETOS</b> .....  | <b>12</b> |
| <b>2.3</b> | <b>MÉTODOS DE DOSAGEM DO CONCRETO</b> .....   | <b>15</b> |
| <b>3</b>   | <b>MACHINE LEARNING</b> .....   | <b>22</b> |
| <b>3.1</b> | <b>HIPERPARÂMETROS EM UM MODELO DE ML</b> .....   | <b>23</b> |
| <b>3.2</b> | <b>TIPOS DE ALGORITMOS DE ML</b> .....  | <b>25</b> |
| 3.2.1      | <i>Support Vector Machine (SVM) - Regression</i> .....  | 25        |
| 3.2.2      | <i>Redes Neurais Artificiais (ANN)</i> .....  | 27        |
| 3.2.3      | <i>Perceptron de Múltiplas Camadas (MLP)</i> .....  | 28        |
| 3.2.4      | <i>Árvores de Decisão ou Decision Trees (DT)</i> .....  | 30        |
| <b>3.3</b> | <b>MACHINE LEARNING APLICADO A CONCRETOS</b> .....  | <b>31</b> |
| <b>3.4</b> | <b>PRINCIPAIS DESAFIOS DE ANÁLISE DE DADOS COM ML</b> .....                                   | <b>40</b> |
| <b>4</b>   | <b>METODOLOGIA</b> .....  | <b>43</b> |
| <b>4.1</b> | <b>ETAPA 1 – OBTENÇÃO DA BASE DE DADOS BRASILEIRA<br/>COMPATIBILIZADA</b> .....               | <b>44</b> |
| <b>4.2</b> | <b>ETAPA 2 - TREINAMENTO DA TÉCNICA DE ML USANDO ANN</b> .....                                | <b>48</b> |
| <b>4.3</b> | <b>ETAPA 3 - ANÁLISE ESTATÍSTICA DA TÉCNICA DE ACORDO COM OS<br/>CASOS APRESENTADOS</b> ..... | <b>52</b> |
| <b>5</b>   | <b>RESULTADOS</b> .....   | <b>55</b> |
| <b>5.1</b> | <b>OBTENÇÃO DA BASE DE DADOS COMPATIBILIZADA</b> .....  | <b>55</b> |
| 5.1.1      | <i>DATA_BR2023</i> .....  | 57        |
| 5.1.2      | <i>DATA_YEH1998</i> .....   | 61        |

|            |   |           |
|------------|---|-----------|
| <b>5.2</b> | <b>TREINAMENTO DA TÉCNICA DE ML USANDO ANN.....</b>                           | <b>64</b> |
| 5.2.1      | <i>Comparação entre Casos.....</i>  | 64        |
| <b>5.3</b> | <b>ANÁLISE ESTATÍSTICA E TÉCNICA DE ACORDO COM OS CASOS APRESENTADOS.....</b> | <b>65</b> |
| 5.3.1      | <i>Caso 1 TR_TE.BR.....</i>   | 66        |
| 5.3.2      | <i>Caso 2 TR_TE.YEH.....</i>  | 66        |
| 5.3.3      | <i>Caso 3 TR.YEH_TE.BR.....</i>   | 67        |
| 5.3.4      | <i>Caso 4 TR.BR_TE.YEH.....</i>   | 67        |
| 5.3.5      | <i>Caso 5 TR_TE.ALL.....</i>  | 67        |
| 5.3.6      | <i>Resumo e Comparação entre Casos.....</i>                                   | 67        |
| 5.3.7      | <i>Análise de Importância (PI).....</i>                                       | 71        |
| <b>6</b>   | <b>CONSIDERAÇÕES FINAIS .....</b>   | <b>74</b> |
| <b>6.1</b> | <b>CONCLUSÕES .....</b>   | <b>74</b> |
| <b>6.2</b> | <b>SUGESTÕES PARA DESENVOLVIMENTOS FUTUROS .....</b>                          | <b>77</b> |
|            | <b>REFERÊNCIAS .....</b>  | <b>78</b> |
|            | <b>APÊNDICE A – Banco de Dados Brasileiro (DATA_BR23).....</b>                | <b>91</b> |

# 1 INTRODUÇÃO

## 1.1 IMPORTÂNCIA DO TEMA

O concreto de cimento portland é um compósito complexo. De acordo com a NBR 12655 (ABNT, 2022) é:

Um material formado pela mistura homogênea de cimento, agregados miúdo e graúdo com ou sem a incorporação de componentes minoritários (aditivos químicos, pigmentos, metacaulim, sílica ativa e outros materiais pozolânicos), que desenvolve propriedades pelo endurecimento da pasta de cimento (cimento e água).

Por uma análise econômica, trata-se de um material de baixo custo se comparado com outros materiais estruturais, mas pode ser considerado complexo pois a interação entre os componentes gera muitos efeitos sobre o material. Esse fator afeta diretamente as propriedades do concreto, sem destacar as variáveis incontroláveis como condições ambientais da concretagem e mão de obra, quando executado em canteiro de obras (VISEDIO e PECCHIO, 2019).

Além disso, segundo Feng *et al.* (2020) o concreto é um dos materiais mais consumidos em todo o mundo. É ele o principal material para construção de casas, prédios, pontes, viadutos e as mais diversas obras. O cimento Portland é seu aglomerante principal e através dele podemos ter uma noção do aumento de sua demanda no setor da construção no Brasil, como demonstrado na Figura 1.1.

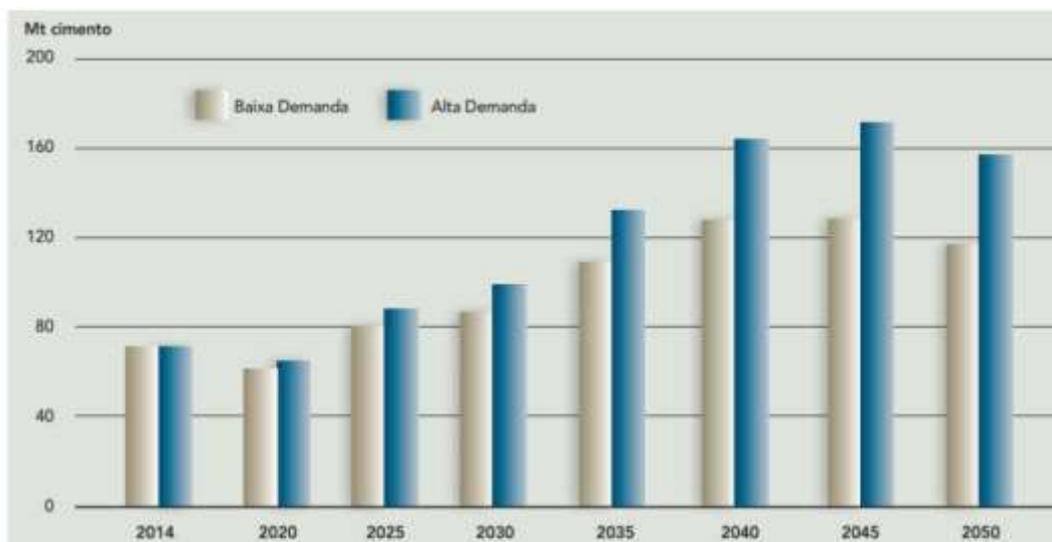


Figura 1.1 Projeção da Produção de Cimento no Brasil para cenários de alta e baixa demanda de materiais.

Fonte: VISEDIO e PECCHIO, 2019

Penna (2023) afirma que a venda de cimentos por dia útil foi de 201 mil toneladas no mês de janeiro de 2023, o que indica um aumento de 2,4% comparado ao mesmo mês do ano anterior. Esses dados foram divulgados pelo Sindicato Nacional da Indústria do Cimento (SNIC) e indicam a ordem de grandeza atual da venda do cimento no Brasil nesse ano. Além disso, demonstram continuidade das obras e vendas imobiliárias como principais motivos para o consumo do produto e alta nas obras de infraestrutura, mesmo com elevada inflação no setor.

Essa alta relevância do concreto aliada à complexidade do material exigem um controle tecnológico. Propriedades no estado fresco, como a consistência pelo ensaio de abatimento, e no estado endurecido, como resistência a compressão e módulo de elasticidade, são alguns dos principais parâmetros para o controle de qualidade exigido pelas normas. A área de métodos matemáticos surge, nesse contexto, para melhorar a análise numérica de resultados desses ensaios, trazendo a possibilidade de predições de algumas dessas propriedades.

Quando o cimento reage com água, ocorre lentamente a reação química de hidratação, e o silicato de cálcio hidratado (C-S-H) é formado. Ele une as partículas dos agregados com a pasta. Esse processo de hidratação começa imediatamente com a adição de água e continua por anos, tornando o concreto um material sólido, estável e resistente (RAMZI; HAJILOO, 2022).

Na área de pesquisa e desenvolvimento no setor da construção civil e ciências dos materiais as técnicas de Machine Learning (ML) vêm sendo utilizadas para predições de diagramas de fase, estruturas cristalinas, propriedades dos materiais, desenvolvimento de potenciais interatômicos e finalmente, para prever as propriedades do concreto. São diversas possibilidades de aplicações que recentemente vêm sendo implantadas em uma escala cada vez maior e surgindo tanto em ambientes acadêmicos como no mercado de trabalho (MUELLER; KUSNE; RAMPRASAD; 2016).

Dessa forma, essa tecnologia apresentou potencial para alcançar pequenas e médias empresas. Como resultado, o uso de inteligência artificial permitiu uma redução de 119 horas por mês dedicadas à realização de ensaios de resistência à compressão, além de aumentar em mais de 200% o número de resultados disponíveis (NERY, 2021).

Isso somente se tornou possível devido a diversos tipos de abordagens e estratégias que utilizam todo o potencial de Machine Learning (ML) e que recentemente vem sendo aplicada na área da construção civil.

## 1.2 MOTIVAÇÃO DA PESQUISA

O trabalho atual segue a linha de pesquisa “Tecnologia, Processos, Componentes e Materiais e Construção” e “Métodos Numéricos e Computacionais Aplicados à Engenharia” do Programa de Pós-graduação em Estruturas e Construção Civil (PECC) da Universidade de Brasília (UnB). Pesquisas envolvendo a temática de ML podem ser encontradas no programa nas áreas de Estruturas realizada por Marcy (2017), Gestão da Construção realizada por Barros (2019) e Materiais de Construção, realizada por Chaves (2022) aplicada para Cimentos Portland sem a adição de materiais cimentícios suplementares.

Visando analisar a importância das pesquisas envolvendo ML para a previsão de comportamento mecânico e quantificá-las realizou-se uma Revisão Sistemática da Literatura (RSL) através da base de dados “Web of Science”. Depois da escolha da base de dados, são escolhidas palavras-chaves e condições de contorno e critérios de seleção. Determinou-se a busca para as palavras-chave: “Machine Learning” e “concrete” na categoria “Civil Engineering” obtendo um total de 827 publicações em inglês até junho de 2023.

No período analisado, entre 1997 até junho de 2023 nota-se tendência de crescimento, com destaque para o ano de 2022 com 310 publicações representando 37,48% do total em 27 anos analisados.

Em 2021, por exemplo, houveram 137 publicações, quase o dobro das publicações do ano anterior. Esse é um indicativo que houve no mundo um grande interesse recentemente em publicar sobre o tema, principalmente devido aos avanços tecnológicos na área de ML. Somente nos três últimos anos 75,81% dos artigos foram disponibilizados. Em 2022, as publicações sobre o tema também quase dobraram se comparadas a 2021.

Em 2023, como no momento da coleta dos dados o ano ainda não havia sido encerrado, houve uma quantidade de trabalhos menor que nos dois últimos anos. Os resultados da pesquisa estão representados na Figura 1.2. Cabe destacar que esse levantamento foi realizado para demonstrar a relevância da temática em termos acadêmicos nos últimos anos e as publicações em questão não foram utilizadas para a composição direta do banco de dados da pesquisa.

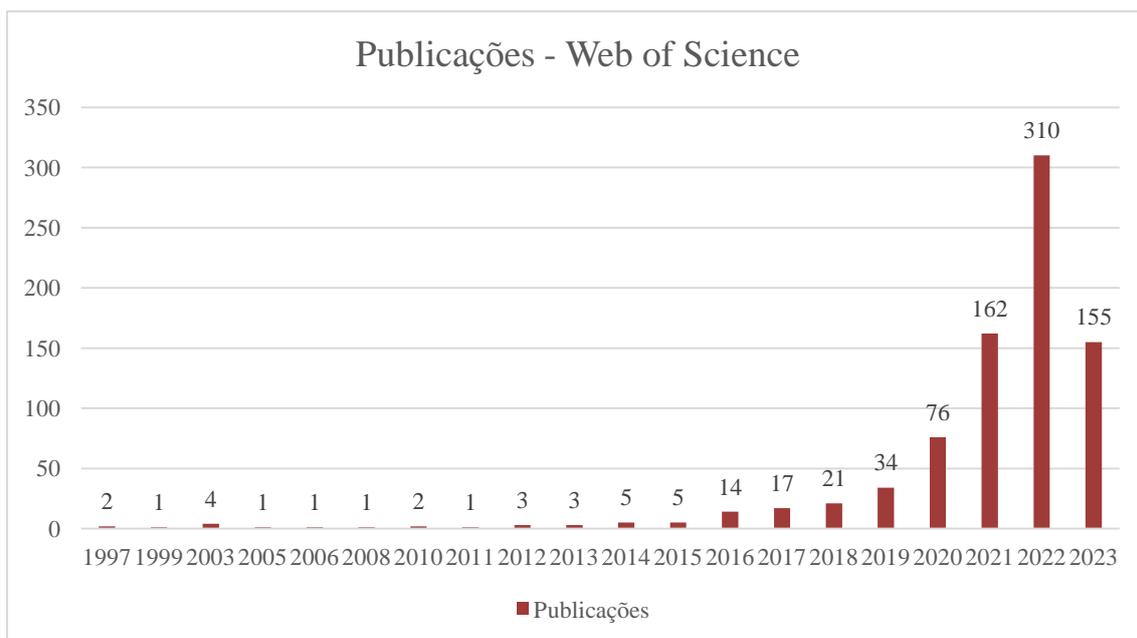


Figura 1.2 – Número de publicações por ano no Web of Science

Fonte: Próprio Autor (2023)

Essa pesquisa se propõe a prever as propriedades de concretos convencionais, com enfoque na resistência a compressão em diferentes idades, utilizando ML através de duas bases de dados. Será utilizado um banco de dados, referente a Yeh (1998) disponível na “UC Irvine Machine Learning Repository” com 1030 instâncias para análise de diferentes algoritmos de ML, além de uma base de dados própria baseada em publicações brasileiras. Essa segunda base de dados foi construída com a intenção de comparar com esta outra disponível no repositório nas etapas de treinamento e teste. Os dados foram computados e analisados com parâmetros estatísticos e numéricos.

### 1.3 OBJETIVOS

#### 1.3.1 Objetivo geral

O objetivo principal da pesquisa é prever a resistência à compressão do concreto através da comparação de duas bases de dados, uma internacional denominada DATA\_YEH1998 e outra nacional denominada DATA\_BR2023, por meio de técnicas de *Machine Learning*.

#### 1.3.2 Objetivos específicos

Os objetivos específicos dessa pesquisa são:

- Realizar a coleta da base de dados brasileira e preparar os dados por meio de limpeza, seleção, tratamento, normalização e padronização, além de uniformizar dados de entrada para comparar com a base de dados do repositório.
- Desenvolver o treinamento e teste das redes neurais artificiais, bem como definição da arquitetura da rede, selecionando os hiperparâmetros e determinando a taxa de aprendizado inicial.
- Avaliar e comparar o desempenho das redes neurais ao utilizar as duas bases de dados distintas, utilizando métricas como erro médio quadrático, coeficiente de determinação ( $R^2$ ) e análise de importância dos dados de entrada utilizando casos de combinações possíveis entre treinamento e teste.

#### **1.4 ESTRUTURA DA DISSERTAÇÃO**

Esta dissertação está organizada em cinco capítulos. O capítulo 1 destina-se à contextualização do tema abordado, à justificativa da pesquisa, assim como à apresentação dos objetivos propostos e da estrutura do trabalho.

O Capítulo 2 trata da revisão bibliográfica de Concretos de Cimento Portland e suas propriedades no estado fresco e endurecido, o uso de materiais cimentícios suplementares e em seguida os principais métodos de dosagem utilizados no Brasil e no mundo.

O Capítulo 3 os três principais algoritmos de ML: Support Vector Machine (SVM), Neural Networks (NN) e Decisions Trees (DT) e conceitos básicos do que são hiperparâmetros e como construir um modelo preditivo.

O Capítulo 4 apresenta a metodologia para a realização da pesquisa, desde a construção da base de dados, os critérios adotados para coleta de dados e sua consequência subdivisão em 5 casos para estudo comparativo entre as duas bases de dados utilizadas.

O Capítulo 5 detalha as bases de dados DATA\_YEH1998 e DATA\_BR2023 através de matrizes de correlação, histogramas e parâmetros de máximos, mínimos, média e desvio padrão. Posteriormente, mostra-se os resultados obtidos para cada caso isoladamente e compara-os para a aquisição daqueles com os melhores desempenhos baseando-se nos resultados estatísticos:  $R^2$ , MSE e RMSE.

Finalmente o Capítulo 6 traz as principais conclusões e sugestões para os trabalhos futuros.

## 2 CONCRETOS DE CIMENTO PORTLAND

Grande parte das peças estruturais e não estruturais são feitas de concreto e fabricadas com diferentes tipos de cimentos e agregados. Esse material confere a propriedade de moldagem, adequando-se aos mais diversos tipos de formas, ao mesmo tempo em que possui capacidade estrutural de carga elevada, alcançando grandes vãos. Por isso esse compósito é um dos mais utilizados nos sistemas estruturais de todo o mundo. (MEHTA, 2014; RAMKUMAR, 2020; SILVA et al, 2012; SOUZA, 2019).

O aglomerante que faz com que o concreto tenha as suas principais propriedades é o Cimento Portland. De acordo com a NBR 16697 (ABNT, 2018) o Cimento Portland é definido como “ligante hidráulico obtido pela moagem de clínquer Portland, ao qual se adiciona, durante a fabricação, a quantidade necessária de uma ou mais formas de sulfato de cálcio e adições minerais.”.

As matérias-primas para a produção do cimento são basicamente: calcário, argila (com os constituintes principais a sílica e alumina) e óxido de ferro, para a produção do clínquer (que representa 95% de sua composição) e gesso (5%). Uma das etapas mais importantes na fabricação do cimento se dá no forno rotativo onde os minerais naturais (farinha) se transformam quimicamente em materiais sintéticos (clínquer). Assim são gerados os principais compostos do clínquer: silicato tricálcico ( $C_3S$ ), silicato dicálcico ( $C_2S$ ), aluminato tricálcico ( $C_3A$ ) e ferroaluminato tetracálcico. ( $C_4AF$ ) (NEVILLE, 2016).

Durante a hidratação do clínquer, que é uma reação exotérmica, a taxa de liberação de calor é um indicativo da velocidade de reação. Nesta etapa, cada um dos componentes do clínquer terá funções específicas. O  $C_3S$  tem importante papel no endurecimento e resistência em estágios iniciais de cura, apresenta-se sob a forma de solução sólida e forma prismática hexagonal. O  $C_2S$  contribui para resistências a longo prazo através do ganho de resistência mecânica após os 28 dias e possui baixo calor de hidratação. Os aluminatos estão presentes na fase intersticial, sendo que o  $C_3A$  reage muito rapidamente com água e o  $C_4AF$  tem importante papel da resistência química dos cimentos, como ao ataque de sulfatos. (LUDWIG; ZHANG, 2015).

O clínquer ao se unir com o gesso e outros materiais cimentícios suplementares forma o cimento. Esse aglomerante quando misturado com agregados miúdos, graúdos, aditivos

químicos e água resulta no concreto convencional. Cada um destes componentes irá atribuir propriedades específicas para o material no estado fresco e endurecido. (YOUNG, 2019)

O concreto adquire uma propriedade de grande relevância para a engenharia estrutural: a resistência à compressão axial. Expressa em Megapascals (MPa), é obtida através do ensaio de compressão axial, demonstrado na Figura 2.1, em corpos de prova cilíndricos usando um método padronizado pela norma brasileira NBR 5739 (ABNT, 2018). Esse ensaio consiste basicamente na aplicação de uma carga de compressão axial uniformemente distribuída em velocidade constante na base do corpo de prova até que o material se rompa.



Figura 2.1- Ensaio de resistência à compressão axial do concreto.

Fonte: (HAYRTON, 2021)

A NBR 16697 (ABNT, 2018) é a norma brasileira atual que especifica os requisitos para a produção dos diversos tipos de cimento: o Cimento Comum (CP I e CPI-S), o Cimento Composto (CP II-F, CP II-E, CP II-Z), Cimento de Alto Forno (CP-III), Cimento Pozolânico (CP-IV) e Cimento de Alta Resistência Inicial (CP V).

O CP I e o CP I-S são os cimentos que apresentam maior teor de clínquer em sua composição, acima de 90%. Isso porque os teores de substituição de outros componentes como escória de alto forno, material pozolânico e material carbonático são relativamente baixos. Conseqüentemente, ocorre um maior impacto ambiental e um custo mais elevado para sua

produção comercial, conseqüentemente esses tipos de cimento são mais difíceis de serem encontrados em estoque. O CP V, por sua vez, possui semelhanças com o CP I visto que possui função de alta resistência inicial fazendo com que seja necessário que esse cimento apresente também alto teor de clínquer combinado com uma maior finura do cimento (LOUZEIRO, 2018).

De acordo com o Roadmap Tecnológico de Cimento (2019), os diferentes tipos de CP II classificados na norma brasileira possuem teores relevantes de materiais cimentícios suplementares. Entre os 3 tipos de CP II, existe a possibilidade de até 49% de substituição do clínquer, podendo conter, por exemplo, no caso do CP II-E, fíler e escória de alto forno, material considerado pozolânico. No CP III, a principal substituição do clínquer também é o subproduto industrial da Escória de Alto Forno que advém de resíduos industriais, porém com teores mais elevados, o que diminui o impacto ambiental e no CP IV as pozolanas provenientes de rochas de origens vulcânicas, como cinzas volantes, ou argilas calcinadas (NEVES, 2019).

Além do cimento, os agregados têm papel fundamental para a fabricação dos concretos. Ocupando  $\frac{3}{4}$  do volume do concreto, eles têm a capacidade de limitar a resistência do concreto, visto que possuem uma resistência à compressão maior que a do concreto, além de poderem reduzir os efeitos das variações volumétricas gerados pela retração (LOUZEIRO, 2018).

A NBR 7211 (ABNT, 2019), é a norma brasileira que especifica os tipos de agregado graúdos e miúdos, os limites máximos aceitáveis de substâncias nocivas e os ensaios característicos. Os agregados miúdos possibilitam melhor trabalhabilidade e coesão da mistura, enquanto que os agregados graúdos influenciam na resistência mecânica do concreto. Isso faz com que, ao trabalharem combinados, suas propriedades físicas, térmicas e, algumas vezes químicas influenciam no desempenho do concreto (OLIVEIRA; FENILLI, 2019).

A combinação precisa de areia e brita no concreto desempenha um papel crucial não apenas na resistência e durabilidade do material, mas também na formulação das dosagens de concreto ideais. A proporção adequada desses agregados, juntamente com o cimento e a água, é um fator determinante para alcançar as características desejadas da mistura final (OLIVEIRA; FENILLI, 2019).

Alguns métodos de dosagem, como o Modelo de Empacotamento Compressível (MEC) propõem como solução um melhor empacotamento das misturas secas em todos os

componentes utilizados na dosagem do concreto, sendo os agregados, componentes essenciais (SILVA, 2004; GOMES; BARROS, 2009).

Já em relação aos aditivos químicos utilizados em concretos, na prática, eles se apresentam normalmente na forma líquida e podem: retardar ou acelerar o tempo de pega, proporcionar maior fluidez a mistura e podem aumentar a resistência à compressão do concreto. Devem ser usados em situações específicas para obter propriedades de diversos tipos de concretos. Além disso, seu uso é normatizado pela NBR 11768 (ABNT, 2019) e sua dosagem é especificada por cada fabricante.

A dosagem do concreto pode ser realizada em diferentes situações. A NBR 12655 (ABNT, 2022) estabelece que a medida volumétrica é aceita somente para concretos que são preparados no próprio canteiro ou combinada com volume em concretos classe C20. Nessa combinação o cimento sempre será medido em massa enquanto que, caso os agregados sejam medidos em volume, o canteiro deve apresentar meios e ferramentas para conversão de massa para volume devido o fator umidade. Nos demais casos, todos os componentes do concreto devem ser medidos em massa. (NEVES, 2019)

Em relação às condições de preparação do concreto brasileiro, a NBR 12655 (ABNT, 2022) estabelece a Condição A, B e C:

- Condição A: todas as classes de concreto nas quais o cimento e os agregados são medidos em massa e a água de amassamento em massa ou volume, sempre utilizando nesse segundo caso um dispositivo dosador e correção em função da umidade dos agregados. Admite um desvio-padrão de 4 MPa.
- Condição B: os agregados são medidos através de uma combinação de massa com volume descritos na norma. Aceita um desvio-padrão de 5,5 MPa.
- Condição C: os agregados são medidos em volume. Possui um desvio padrão máximo de 7 MPa.

Além disso, existe o concreto usinado dosado em central, normatizado pela NBR 7212 (ABNT, 2021), que faz com que seu preparo e mistura seja realizado anteriormente para que já chegue pronto na obra. É comum que esse tipo de concreto seja bombeado com mangueiras diretamente no local de aplicação, pois a mistura é mais fluida que o concreto convencional e aceita no máximo um desvio-padrão de 5 MPa no caso de centrais que dosam o cimento em sacos. Esse

concreto possui três vantagens principais: reduz o número de trabalhadores na obra, possibilita maior agilidade e produtividade no canteiro de obras e ainda entrega um serviço final com maior custo-benefício. Suas propriedades no estado fresco são essenciais para a sua aplicação e trabalhabilidade (ANVERSA, 2020).

## 2.1 PROPRIEDADES DO CONCRETO NO ESTADO FRESCO

As principais propriedades do concreto no estado fresco são: trabalhabilidade, segregação, plasticidade, exsudação e teor de ar incorporado (NEVES, 2019).

A trabalhabilidade do concreto pode ser resumida como a quantidade de trabalho interno necessária para atingir a compactação máxima do material (NEVILLE, 2016). Para caracterizar o comportamento deste trabalho interno e a aparência da mistura fresca, métodos qualitativos (por exemplo, aspereza, coesividade, rigidez, compactabilidade), quantitativos empíricos (por exemplo, abatimento) ou quantitativos fundamentais (por exemplo, viscosidade, fluidez, valor de rendimento) podem ser usados (SILVA; BRITO; DHIR, 2018). Os métodos empíricos quantitativos fornecem uma única medição e, portanto, são referidos como testes de um parâmetro ou de ponto único.

Os métodos *Slump* e *Slump Flow*, que pertencem a esta categoria, foram os métodos mais amplamente utilizados para caracterizar a trabalhabilidade de concretos com agregados reciclados e são a base da avaliação nas seções seguintes, salvo indicação em contrário. A abordagem mais adequada para efetivamente quantificar e avaliar a trabalhabilidade do concreto é com a aplicação de testes de dois parâmetros ou dois pontos, que fornecem propriedades fundamentais para o estudo da reologia do concreto (ou seja, tensão de escoamento e viscosidade plástica) (SILVA; BRITO; DHIR, 2018).

Nesse contexto, existem vários fatores que afetam a trabalhabilidade do concreto fresco. Um deles é o teor de água na mistura, expresso em quilogramas (ou litros) de água por metro cúbico de concreto. A adição ou não de aditivos para funções específicas como retardadores de pega e superplastificantes devem ser considerados em conjunto pois afetam a trabalhabilidade (HERNANDEZ, 2017).

Pode-se exemplificar esse fato considerando que concretos com ar incorporado, assim como mostrado na Figura 2.2, podem ter o teor de água reduzido, isso porque o efeito do ar

incorporado na trabalhabilidade depende das proporções da mistura. Caso o teor de água e as outras proporções da mistura sejam constantes, a trabalhabilidade é determinada pela dimensão máxima do agregado, sua forma e a sua textura (NEVILLE, 2016).

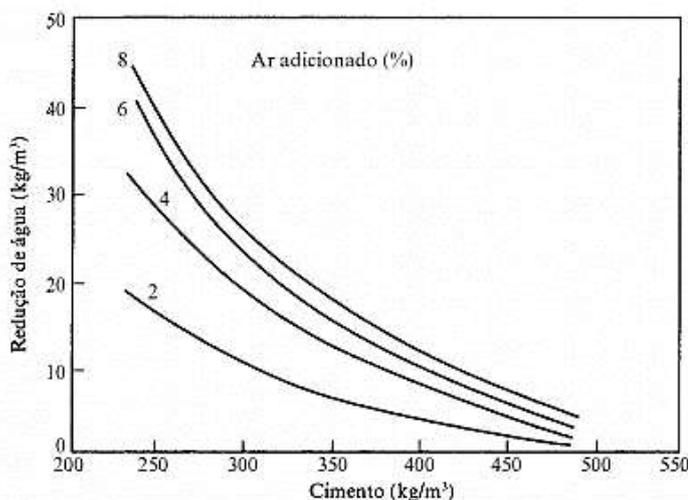


Figura 2.2 - Redução na demanda de água de amassamento devido à adição por aditivo incorporador de ar

Fonte: Neville (2016)

O *slump test*, ou ensaio de abatimento, é um ensaio padrão para verificar a consistência e indiretamente a trabalhabilidade do concreto através de um tronco de cone. É realizado na maioria das vezes no próprio canteiro de obras e faz parte do controle tecnológico do concreto. Esse ensaio deve ser realizado com o concreto fresco antes do lançamento independentemente de se tratar de um concreto usinado dosado em central ou um concreto produzido na obra. A amostragem, aparelhos necessários e demais métodos de ensaio estão descritos na NBR 16889 (ABNT, 2019).

A segregação e a exsudação são duas propriedades indesejadas na mistura final. A segregação ocorre quando as partículas mais grosseiras se movimentam no sentido da gravidade, acumulando-se na parte inferior e os finos em direção contrária causando a separação dos agregados. A exsudação, por sua vez, está relacionada com o movimento ascendente de água na superfície do concreto e pode ser consequência de um adensamento ruim. Finalmente, o concreto em seu estado fresco deve apresentar também boa plasticidade, ou seja, não se romper quando moldado e também depende da sua dosagem. Massas com agregado com granulometria

mais fina tendem a ser ásperas e coesivas com alta plasticidade (SOBRAL, 2000; BIZINOTTO; FALESCHINI; FERNÁNDEZ; HERNÁNDEZ, 2017).

Resumidamente, as propriedades do concreto fresco são muito importantes e indispensáveis no controle tecnológico. Os parâmetros de dosagem referentes ao tipo de aditivo, sua quantidade, a quantidade de água e a granulometria dos agregados e o tipo de cimento são aqueles que mais afetam as suas propriedades no estado fresco (SOBRAL, 2000; BIZINOTTO; FALESCHINI; FERNÁNDEZ; HERNÁNDEZ, 2017).

Além do estado fresco, o concreto também possui propriedades no estado endurecido. Nesse estado, o concreto exibe diversas propriedades mecânicas e físicas que o tornam um material de construção altamente versátil e confiável. Suas principais características incluem: resistência à tração, embora relativamente baixa, pode ser melhorada com o uso de armaduras de aço; excelente durabilidade, resistindo a ações químicas, intemperismo e ao desgaste; baixa permeabilidade, impedindo a penetração de líquidos e gases e, por fim, resistência à compressão, que é a capacidade de suportar cargas verticais sem deformação excessiva.

## **2.2 RESISTÊNCIA À COMPRESSÃO EM CONCRETOS**

A resistência à compressão é um dos principais parâmetros de controle tecnológico associado ao concreto em seu estado endurecido, dado em Megapascal (MPa). Essa propriedade pode ser explicada fisicamente como sendo a tensão do material, ou seja, o quanto de força o material consegue resistir em relação a uma determinada área, detalhados pela NBR 5739 (ABNT, 2018).

Os ensaios de resistência permitem confirmar a tensão máxima que o material (ou corpo de prova) irá suportar antes do rompimento, isso devido ao estado de fissuração interna atingido (NEVILLE, 2016; MEHTA; MONTEIRO, 2014).

Segundo a NBR 5739 (ABNT, 2018) a determinação da resistência do concreto (em  $f_{ck}$ ) é dada por ensaio de compressão axial em corpos de prova cilíndricos. Esse corpo de prova é submetido a um carregamento progressivo até a ruptura. O valor da força exercida pela máquina no momento da ruptura dividido pela área de concreto em contato com a prensa é a resistência máxima do material. Esse parâmetro é fundamental para a análise estrutural em elementos que são bastantes solicitados à compressão como pilares feitos de concreto armado, por exemplo.

Além disso a NBR 12655 (ABNT, 2022) define as diretrizes e procedimentos quanto à preparação e ao recebimento ou aprovação do concreto, incluindo critérios de preparo, controle, recebimento e aceitação da resistência mecânica.

Além de parâmetro de resistência, a resistência a compressão pode ser utilizada como parâmetro de durabilidade. Isso porque os fatores que elevam a resistência da matriz cimentícia também aumentam a impermeabilidade e a durabilidade (NEVES, 2019). A relação água/cimento, inserida na Lei de Abrams, é representada pela seguinte equação:

$$f_c = \frac{k_1}{k_2 \frac{a}{c}} \quad (1)$$

Onde,  $a/c$  é a relação água/cimento de dosagem,  $k_1$  e  $k_2$  constantes empíricas e  $f_c$  a resistência a compressão do concreto (MEHTA; MONTEIRO, 2014). A  $a/c$  influencia diretamente a resistência e durabilidade de uma maneira inversamente proporcional, quanto menor essa relação maior a resistência. Geralmente, essa relação está estabelecida na Tabela 2 da NBR 12655 (ABNT, 2020) e varia entre 0,45 e 0,65, além de estar diretamente relacionada com a classe de agressividade do meio.

Essa relação é materializada durante a concretagem, existe uma tendência para a adição de mais água para que o concreto apresente melhor trabalhabilidade, porém deve ser controlada por profissional especializado visto que pode afetar a resistência final de determinado elemento estrutural. Por isso, existem aditivos específicos e estudos de métodos de dosagem para se obter boas propriedades, tanto no estado fresco quanto no estado endurecido.

Wang *et al.* (2022) investigou os efeitos das relações água-cimento 0,3; 0,4 e 0,5 no desempenho de concreto após cura de 28 dias. Nessa pesquisa os resultados experimentais mostraram que uma relação  $a/c$  mais baixa reduziu efetivamente a porosidade do concreto e aumentou a resistência à compressão do concreto.

Outro estudo realizado por Medeiros-Junior *et al.* (2014) investigou a influência da quantidade de água na resistência à compressão do concreto. Os resultados também mostraram que o aumento da quantidade de água resultou em uma diminuição da resistência à compressão, comprovando essa relação. Isso ocorre porque o excesso de água pode prejudicar a formação

adequada das ligações químicas entre os grãos de cimento, agregados e aditivos, comprometendo a resistência do concreto.

A qualidade dos agregados, tanto o agregado miúdo quanto o agregado graúdo, também influencia na resistência à compressão do concreto. Um estudo realizado por Rodrigues e Fucale (2014) investigou a dosagem de concretos produzidos com agregado miúdo reciclado de resíduos da construção civil (RCD). O estudo mostrou que a utilização de agregados miúdos reciclados pode afetar as propriedades mecânicas do concreto, incluindo a resistência à compressão. Isso ocorre porque os agregados reciclados podem apresentar características diferentes dos agregados naturais, como maior quantidade de vazios e resistência mecânica inferior.

Um estudo mais recente realizado por Ortolan (2022) avaliou o desempenho de concretos com agregados RCD. O estudo mostrou que a adição de cinza volante nesses concretos causou diminuição das propriedades mecânicas e de durabilidade dos concretos nas primeiras idades. A dosagem ideal foi obtida ao se obter 30% de agregado reciclado e 15% de cinza volante.

Além disso, a utilização de materiais cimentícios suplementares, como cinza volante, fíler calcário e argila calcinada, pode influenciar a resistência à compressão do concreto. Um estudo realizado por Oliveira e Barbosa (2006) avaliou as potencialidades de um caulim calcinado como material de substituição parcial do cimento Portland em argamassas. O estudo mostrou que a adição de caulim calcinado pode melhorar as propriedades mecânicas do concreto, incluindo a resistência à compressão. Isso ocorre porque o caulim calcinado atua como um material pozolânico, reagindo com o hidróxido de cálcio presente no cimento Portland e formando produtos de hidratação que contribuem para o aumento da resistência do concreto.

Em resumo, a resistência à compressão do concreto é influenciada por diversos fatores, incluindo a quantidade de água, o tipo de aditivo, a granulometria e a qualidade dos agregados, bem como o consumo de cimento. Além disso, a utilização de materiais cimentícios suplementares, como cinza volante e argila calcinada, pode afetar negativamente a resistência à compressão do concreto nas idades iniciais ou positivamente em idades avançadas enquanto que o fíler calcário funciona como material de preenchimento. É importante considerar esses fatores durante o processo de dosagem e produção do concreto, a fim de garantir a obtenção de um material com resistência adequada para as aplicações desejadas (ORTOLAN, 2022).

## 2.3 MÉTODOS DE DOSAGEM DO CONCRETO

Para que um concreto de alta qualidade possa ser produzido é necessário um adequado e eficiente método de dosagem que especificará a proporção ideal em massa ou volume de cada um dos componentes do concreto definidos pela NBR 12655 (ABNT, 2022).

Cada vez mais o mercado e as técnicas construtivas exigem concretos de alta resistência, concretos de alto desempenho, concretos autoadensáveis, concretos com altos teores de materiais cimentícios suplementares, como pozolanas e escórias de alto forno, concretos aparentes; concretos coloridos, concretos brancos, concretos com agregados reciclados e diversos outros. Para cada um destes existe, na literatura especializada, uma série de métodos de dosagem que visam formular um concreto com o menor custo.

Dessa forma não existe um método de dosagem universal. Muitas das técnicas utilizadas por tecnólogos do concreto se dão experimentalmente e com o auxílio de algumas metodologias mais comuns em cada país. Apesar disso a qualidade e quantidade dos materiais influencia diretamente nas propriedades finais do concreto. Um maior consumo de cimento, por exemplo, no concreto acarreta maior plasticidade, coesão, calor de hidratação e variação volumétrica, além de menor segregação e exsudação (GÓRA, PIASTA, 2020).

Em relação a quantidade de cimento, o traço do concreto no Brasil pode ser classificado como “rico” e “pobre”. Um traço de concreto é considerado "rico" quando contém uma quantidade relativamente maior de cimento em relação aos agregados. Isso geralmente resulta em um concreto mais resistente, com maior resistência à compressão. Traços ricos são frequentemente utilizados em aplicações que exigem alta resistência, como em estruturas de suporte, pilares e fundações. Consequentemente, um traço denominado "pobre" é aquele que contém uma quantidade menor de cimento em relação aos agregados. Concretos com traço pobre têm menor resistência à compressão e, geralmente, são usados em aplicações não estruturais, como revestimentos e acabamentos, onde a resistência não é uma prioridade (OLIVEIRA; FENILLI, 2019).

Um maior consumo de agregado miúdo, por outro lado, acarreta um maior consumo de água e cimento ao mesmo tempo que aumenta a plasticidade. Finalmente, em relação ao agregado

gráudo quanto mais arredondados e lisos seus grãos, maior a plasticidade e menor a aderência do concreto. Dessa forma recomenda-se a utilização de grãos com formato mais rugosos para melhor aderência e próximos a formatos cúbicos. Formatos lamelares tendem a consumir mais cimento, areia, água e influenciar numa resistência final do concreto mais baixa (CURTI, 2010).

Torrales *et al.* (2018) comparou os três principais métodos de dosagem utilizados no Brasil para concretos convencionais com resistência a compressão fixada em 25 MPa, sendo eles: Método ABCP, O'Reilly e IPT.

1) No Método ABCP fixa-se a relação água-cimento e é determinada por critérios de durabilidade e resistência mecânica. Quanto a resistência utiliza-se as curvas de Walz nas quais tem-se a relação água/cimento no eixo x e a resistência a compressão no eixo y.

2) O Método O'Reilly busca a melhor compacidade da mistura definindo fatores como água, resistência a compressão e relação água/cimento. Nesse método, a quantidade ideal dos agregados é aquela que possui a menor quantidade de vazios.

3) O Método do IPT é baseado num estudo experimental de um “teor de argamassa ideal para o recobrimento do agregado gráudo utilizado”. Suas duas principais etapas são: determinação do teor de argamassa ideal e esboço gráfico em um ábaco de dosagem (TORRALES *et al.*, 2018).

As conclusões obtidas pelos pesquisadores é que a utilização do Método de O'Reilly não causou redução significativa do consumo de cimento se comparada com o método ABCP, devido às especificidades dos agregados utilizados. O Método do IPT foi considerado o mais eficiente em termos de otimização de desempenho mecânico dos materiais utilizados, além de possuir traços de curvas de dosagens próprias. Por fim, os Métodos do IPT e da ABCP são alternativas interessantes para a dosagem de concretos convencionais, sendo que o segundo ainda pode ser otimizado ao utilizar curvas de Walz próprias (TORRALES *et al.*, 2018).

Nascimento (2019) também compara o Método IPT com o Método da ABCP e para atingir uma resistência de dosagem pré-estabelecida de 32 MPa. No método ABCP o teor de argamassa ideal foi de 56% com traço 1:2,36:2,64 (cimento, areia e brita) enquanto que no método IPT o traço foi de 1:2,02:2,38 (cimento, areia e brita). Em relação ao consumo de materiais, o método

ABCP tem maior consumo de agregados em relação ao Método IPT para alcançar a mesma resistência, tendo portanto um custo de produção menor.

A Figura 2.3 mostra o resultado das resistências a compressão aos 7 e 28 dias dos três métodos analisados. Observa-se que aos 28 dias, os Métodos O'Reilly e ABCP apresentam resistências próximas pois possuem traços parecidos e são baseados nas mesmas curvas. O Método do IPT apresentou pior desempenho mecânico que pode ser explicado pelo fato de não ter sido utilizado aditivo na mistura, apresentando uma relação água/cimento alta, além de uma maior proporção de agregados no traço.

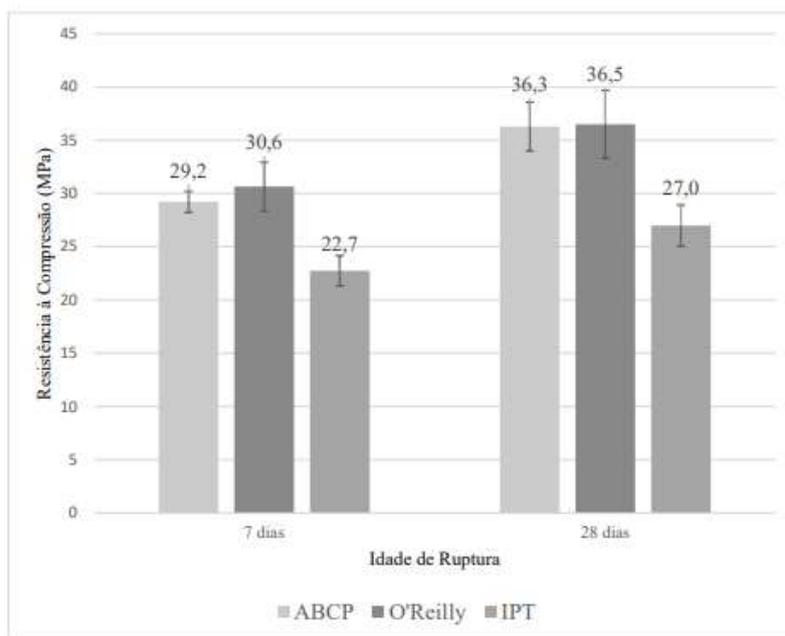


Figura 2.3- Relação entre resistência a compressão (MPa) e idade de ruptura nos três métodos de dosagem analisados.

Fonte: (TORRALES *et al.*, 2018)

Ziolkowski e Niedostatkiewicz (2019) afirmam que a prática de dosagem de concretos na engenharia corporativa europeia mostram três métodos mais utilizados: o método Bukowski, o método Eyman e Klaus e o método Paszkowski. Todos eles são derivados do “Método das Três Equações” ou Método Bolomey, que é um procedimento analítico experimental misto, que utiliza dados coletados em laboratório e abordagem matemática. Calcula-se um volume de componentes necessários por medidas analíticas e os resultados são validados por testes laboratoriais destrutivos.

Segundo Tutikian e Helene (2011) existem três leis clássicas de tecnologia do concreto que são modelos de comportamento da interação entre os componentes do concreto, sendo elas:

- Modelo de Powers (1966), ou Lei de Abrams (1918): já determinado anteriormente que determina: “a resistência de um concreto, numa determinada idade ( $f_{cj}$ ) é inversamente proporcional à relação água cimento ( $a/c$ ).
- Lei de Lyse (1932): “fixando-se o cimento e agregados, a consistência do concreto fresco depende preponderantemente da quantidade de água por  $m^3$  de concreto”.
- Lei de Priszkulnik & Kirilos (1974): “o consumo de cimento por  $m^3$  de concreto varia na proporção inversa da relação em massa seca de agregados/cimento ( $m$ ).”

A resistência à compressão do concreto é influenciada de maneira significativa pelos agregados miúdos e graúdos presentes em sua composição. Esses agregados desempenham papéis cruciais na formação de uma estrutura coesa e resistente. Em primeiro lugar, eles preenchem os espaços vazios entre as partículas de cimento, resultando em uma matriz de concreto mais densa quando presentes em maior quantidade. Esse preenchimento adequado contribui para uma maior resistência à compressão, uma vez que reduz a quantidade de pasta de cimento necessária (GÓRA, PIASTA, 2020).

Além disso, os agregados graúdos têm um papel importante no concreto, proporcionando um intertravamento eficaz. Devido ao seu tamanho maior, esses agregados criam uma conexão robusta entre as partículas, permitindo a transferência eficiente de cargas de compressão. O intertravamento resultante distribui o estresse de uma partícula para outra, promovendo uma maior resistência à compressão no concreto. (MEHTA; MONTEIRO, 2014; NAYAK *et al.*, 2022).

A resistência intrínseca dos agregados também é um fator determinante. Se os agregados miúdos e graúdos utilizados possuírem uma resistência mecânica baixa, isso pode limitar a resistência geral do concreto. Portanto, é fundamental selecionar agregados de alta qualidade, que atendam aos requisitos de resistência especificados, para garantir a robustez do concreto (CHAVES *et al.*, 2021; LUDWIG; ZHANG, 2015).

S.K., Singh e Chourasia (2020) analisam como diferentes composições mineralógicas utilizadas como agregado miúdo influencia diretamente na composição e na sua escolha para a correta dosagem do concreto. A presença de uma maior porcentagem de finos pode resultar em maior

demanda de água e maior porcentagem de aditivos. Portanto, a remoção de finos por vários métodos pode produzir concreto eficiente com propriedades aprimoradas. Além disso, os finos contribuem para o conteúdo de enchimento do concreto autoadensável e podem ser usados para fabricar compósitos leves. A Figura 2.4 mostra como areias de granito, por exemplo, apresentam grãos mais finos que aquelas compostas de diorito.

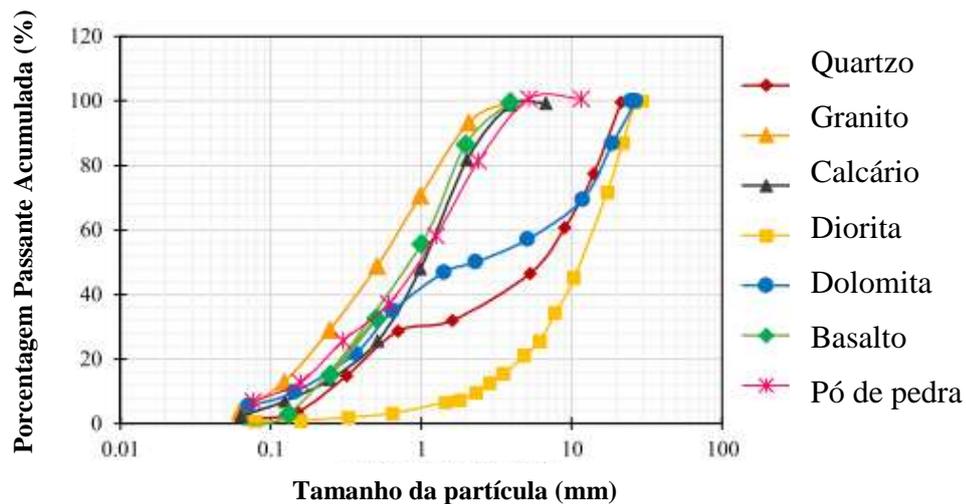


Figura 2.4 Distribuição Granulométrica para diferentes mineralogias de agregados.

Fonte: S.K., Singh e Chourasia, 2020

Dessa forma, a distribuição granulométrica dos agregados é relevante. Uma distribuição granulométrica adequada, com proporções adequadas de diferentes tamanhos de partículas, resulta em uma compactidade otimizada e um melhor empacotamento dos agregados. Esse arranjo favorece a resistência à compressão do concreto, promovendo uma estrutura mais coesa e resistente.

Não somente a distribuição de grãos se mostra relevante. Os concretos de ultra alto-desempenho (UHPC) surgiram num contexto em que se procura a melhor dosagem dos materiais possível para aplicações específicas. Apesar de utilizar materiais e técnicas diferentes do concreto convencional permite analisar como a as propriedades reológicas podem impactar diretamente na resistência à compressão.

As propriedades reológicas do UHPC referem-se às propriedades de deformação e fluxo sob a ação de forças externas. A tensão de escoamento e a viscosidade plástica são dois parâmetros reológicos principais do UHPC. A tensão de escoamento é a tensão máxima que impede a deformação plástica do UHPC, e a viscosidade reflete as características de fluxo do UHPC e determina a dispersão e a orientação das fases na matriz fresca do UHPC. UHPC com

propriedades reológicas adequadas pode levar a distribuição uniforme de fibras e resistência mecânica satisfatória e tenacidade (ZHOU; WU; OUYANG; HU; SHI, 2021).

A Figura 2.5 demonstra as relações da microsilica, ar incorporado, água, cinza volante e superplastificante se comportam em relação a tensão de escoamento e viscosidade plástica no UHPC. Esse concreto pode ser utilizado parâmetro para se obter a melhor dosagem possível ao se utilizar SCM's.

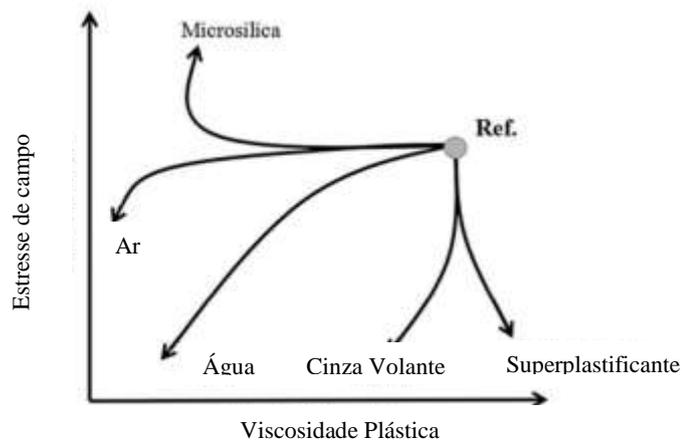


Figura 2.5 Efeitos dos componentes na reologia do concreto.

Fonte: Adaptado de (ZHOU; WU; OUYANG; HU; SHI, 2021)

A Tabela 2.1 resume os principais tipos de dosagem em UHPC gradativamente em relação ao seu desenvolvimento científico ao longo do tempo. Nota-se uma tendência inicialmente empírica que evolui para métodos matemáticos e atualmente incorporam conceitos de inteligência artificial que conseguem resultados de modelagem melhores.

| Método                                       | Princípios da dosagem   | Tipo de concreto | Referências                           |
|--|---|------------------|---------------------------------------|
| <b>Método do empacotamento de partículas</b> | Garante o empacotamento mais consistente das partículas sólidas do concreto variando a proporção de componentes de cimentação e agregados finos e obtenha maior resistência e durabilidade. | UHPC             | (POWERS, 1968) e (AIM; LE GOFF, 1968) |

|   |   |      |                           |
|---|---|------|---------------------------|
| <b>Método baseado nas propriedades reológicas da pasta</b>          | Com base na relação entre reologia e matérias-primas, o tipo e a proporção de cada componente são ajustados continuamente para atingir as propriedades reológicas desejadas do concreto para garantir o melhor desempenho.  | UHPC | MEDHIPOUR; KHAYAT, 2017)  |
| <b>Método de projeto de mistura estatística</b>                     | A proporção de matérias-primas é considerada variável e o desempenho do concreto é tratado como uma resposta. Determinar a proporção ótima de mistura de concreto através do emprego de modelos relevantes para analisar resultados experimentais com erros eliminados. | UHPC | (FERDOSIAN; CAMÕES, 2017) |
| <b>Método de dosagem baseado em redes neurais artificiais (ANN)</b> | Treine o modelo ANN usando muitos dados experimentais e ajuste constantemente os pesos de entrada e saída para reduzir a lacuna entre os valores experimentais e previstos.   | UHPC | (TAN; SUN; NAN, 2020)     |

Tabela 2.1 Resumo de métodos de dosagem pra UHPC.

Fonte: Adaptado de (ZHOU; WU; OUYANG; HU; SHI, 2021)

A evolução dos métodos de dosagem dos UHPC mostra uma tendência ao uso de redes neurais para otimização de dosagem. A previsão da resistência à compressão em cimentos e concretos através do uso de métodos matemáticos e simuladores com inteligência artificial tem ganhado destaque nas pesquisas, uma vez que é uma alternativa para otimizar o processo e evitar erros. Porém, para isso a escolha de dados confiáveis para aplicação dos métodos e normalização, além da confiabilidade, proporciona padronização capaz de auxiliar a comparação dos resultados (ROCHA; MAIA; JÚNIOR; DIAS; VELOSO, 2020).

### 3 MACHINE LEARNING

A área de ML, também conhecida como Aprendizado de Máquina, tem contribuído muito para o avanço científico utilizando inteligência artificial nas diversas áreas do conhecimento: comércio, jogos, saúde, estética e ciência dos materiais (MUELLER, KUSNE, RAMPRASAD; 2016).

Os algoritmos de ML podem ser classificados em duas categorias: aprendizado supervisionado e não supervisionado. Em ambos o algoritmo necessita acessar observações conhecidas como dados de treinamento. No primeiro caso, são inseridos os dados de input (entrada) e output (saída), com esses dados o algoritmo tenta identificar uma função que procura prever com acurácia os dados de saída associados a novos dados de entrada. No aprendizado não supervisionado, por outro lado, não existem dados de saída inseridos no treinamento, de forma que o objetivo é identificar os padrões nos dados de entrada. Ainda existe o treinamento semi-supervisionado no qual nem todos os dados de entrada possuem dados de saída correspondentes, porém para a análise da seguinte pesquisa aplicada em ciências dos materiais não é tão aplicada (MUELLER; KUSNE; RAMPRASAD, 2016).

O uso de modelagem assistida por computador para prever as propriedades mecânicas de materiais de construção está crescendo (CHOU *et al.*, 2023). A aprendizagem de máquina é um ramo importante da inteligência artificial que lida com o design e desenvolvimento de algoritmos capazes de identificar padrões complexos em dados experimentais, sem considerar uma equação predeterminada como modelo, e tomar decisões inteligentes (BEKKERMAN; BILENKO; LANGFORD, 2011; IMONIN; KANEVSKI; POZDNOUKHOV, 2009).

Em geral, o objetivo da aprendizagem de máquina é construir sistemas computacionais que aprendam com a experiência e possam se adaptar aos seus ambientes. Exemplos importantes de aprendizagem de máquina incluem mineração de dados (como busca por informações na web) e implementação de sistemas de software complexos, como direção automática. Modelos baseados em aprendizagem de máquina podem fazer previsões e descrever aquisição de conhecimento a partir de dados (MURPHY, 2012; MARSLAND, 2014).

O escopo e o potencial da aprendizagem de máquina são muito mais amplos do que a IA e englobam muitas disciplinas, incluindo teoria da informação, probabilidade, estatística, psicologia e neurobiologia, controle computacional de complexidade, teoria e filosofia.

Pesquisadores avaliam algoritmos de aprendizagem de máquina pela precisão da solução, qualidade da solução e velocidade de desempenho (TAFFESE, 2017).

Geralmente, o desenvolvimento de um modelo de aprendizagem de máquina envolve um pequeno número de escolhas de projeto: (i) o tipo de experiência de aprendizagem, (ii) o desempenho do objetivo de aprendizagem, (iii) exibição do desempenho alvo; e (iv) um algoritmo para aprender o desempenho objetivo de exemplos instrutivos (MOEIN; SARADAR; RAHMATI; MOUSAVINEJAD; BRISTOW; ARAMALI; KARAKOUZIAN, 2023).

As tarefas dos sistemas de aprendizagem de máquina podem ser resumidas da seguinte forma (BEKKERMAN, BILENKO, LANGFORD, 2011; TAFFESE, 2017) : 1) Classificação: o objetivo desta etapa é identificar a categoria à qual a entrada pertence, 2) Regressão: o formato de saída nesta etapa é considerado como a diferença em relação à etapa de classificação. Esta etapa visa modelar as relações entre as entradas e saídas numéricas, 3) Previsão: o objetivo é prever valores futuros ao longo de um período determinado de tempo. Esta etapa é um tipo especial de regressão, 4) Agrupamento: extrair pontos semelhantes entre dois ou mais conjuntos de dados.

O agrupamento é realizado de acordo com um método não supervisionado, em vez das tarefas definidas para as três etapas anteriores (classificação, regressão e previsão), que são realizadas com base em métodos supervisionados. Antes de iniciar a análise de dados por algoritmos de aprendizagem de máquina, uma das coisas mais importantes é a normalização dos dados. A normalização dos dados é uma das atividades mais comuns na aprendizagem de máquina. Entre as vantagens da normalização dos dados, podemos mencionar a melhoria do desempenho do gradiente descendente em dados normalizados em comparação com dados não normalizados (CHENG; WANG, 2013; VIKHAR, 2017).

### **3.1 HIPERPARÂMETROS EM UM MODELO DE ML**

Em cada caso, foram utilizados hiperparâmetros específicos do modelo, que são configuráveis pelo usuário, que são: solver, alpha, número de neurônios, função ativação e taxa de aprendizado inicial (GOODFELLOW, COURVILLE; 2016).

O solver refere-se ao algoritmo de otimização usado para ajustar os pesos e os vieses da rede neural durante o processo de treinamento. Existem vários solvers disponíveis, como o algoritmo

de descida de gradiente estocástico (SGD), o otimizador Adam, o RMSprop, entre outros. Cada solver possui suas próprias características e propriedades, e a escolha adequada depende do problema e dos dados em questão (YANG; SHAMI, 2020).

Outro hiperparâmetro importante é o alpha, também conhecido como taxa de regularização, é usado para controlar a regularização nos modelos de redes neurais. A regularização é uma técnica usada para evitar o overfitting (sobreajuste) durante o treinamento, adicionando um termo de regularização à função de perda do modelo. O valor de alpha determina a força da regularização aplicada. Valores maiores de alpha aumentam a penalidade para pesos maiores, levando a uma rede neural mais regularizada (GOODFELLOW, COURVILLE; 2016).

O número de neurônios refere-se à quantidade de unidades de processamento em cada camada da rede neural. Essa é uma decisão crucial ao projetar a arquitetura de uma rede neural, pois o número de neurônios em cada camada afeta diretamente a capacidade de representação e a complexidade do modelo. Um número menor de neurônios pode levar a um modelo menos capaz de aprender padrões complexos, enquanto um número maior pode aumentar a capacidade, mas também aumentar o risco de overfitting (YANG; SHAMI, 2020).

A função de ativação determina o valor de saída de um neurônio com base em sua entrada ponderada. É uma parte essencial de cada neurônio, pois introduz não-linearidades na rede neural, permitindo que ela aprenda e represente relações complexas nos dados. Existem várias funções de ativação comumente usadas, como a função sigmoide, a função tangente hiperbólica, a função ReLU (Rectified Linear Unit), a função softmax, entre outras. A escolha da função de ativação depende do tipo de problema e da natureza dos dados (YANG; SHAMI, 2020).

A taxa de aprendizado inicial (*learning rate*) é um hiperparâmetro que define o tamanho do passo que o algoritmo de otimização dá ao ajustar os pesos da rede neural durante o treinamento. Uma taxa de aprendizado alta pode acelerar o treinamento inicialmente, mas também pode fazer com que o algoritmo salte por cima de mínimos locais na função de perda. Por outro lado, uma taxa de aprendizado muito baixa pode fazer com que o treinamento seja lento ou fique preso em mínimos locais. Encontrar a taxa de aprendizado adequada é um desafio e muitas vezes requer ajuste e experimentação. Além disso, algumas técnicas de otimização adaptativa, como o otimizador Adam, ajustam automaticamente a taxa de aprendizado durante o treinamento. (GOODFELLOW, COURVILLE; 2016).

## **3.2 TIPOS DE ALGORITMOS DE ML**

A seguir são apresentados os três principais algoritmos de ML aplicados a previsão de resistência à compressão, de acordo com os artigos publicados sobre o tema, que são: Support Vector Machine (SVM), Neural Networks (NN), Decisions Trees (DT).

### **3.2.1 Support Vector Machine (SVM) - Regression**

As Máquinas de Vetores Suporte ou SVM do inglês, Support Vector Machine, são algoritmos que representam uma família de modelos de regressão que são eficazes para problemas não lineares. O SVM é baseado na teoria do aprendizado estático e minimiza os riscos estruturais associados ao erro de generalização, minimizando os erros sobre a base de dados. Esse modelo de classificação de ML visa encontrar um hiperplano ideal separando-se em duas classes diferentes. Dessa forma, para obter um melhor desempenho nas classificações dos dados do teste, ocorre uma maximização da margem, que representa a distância do hiperplano ao ponto mais próximo da classe (VAPNI; KORTZ, 2006; ANDRADE, 2016).

Essa mesma técnica ainda pode ser associada como método de regressão, que se diferencia dos problemas de classificação ao se basear na previsão de um rótulo ou denominação enquanto que na regressão tem o objetivo de prever uma quantidade. Quando aplicado com o método de regressão é denominado Support Vector Regression (SVR). O SVR tem a função de aproximar o mapeamento dos dados de entrada para números reais com base em uma amostra de treinamento. Tanto o SVM quanto o SVR buscam encontrar um hiperplano ideal separando em duas classes distintas. A Figura 3.1 mostra um exemplo da representação gráfica desse hiperplano, sendo a linha contínua central o hiperplano em si e as linhas tracejadas os limites superiores e inferiores. Ao considerar o SVR, o hiperplano prevê os dados de saída ao considerar que os pontos estão dentro do limite da decisão, a linha de melhor ajuste é aquela que englobar o maior número de pontos.

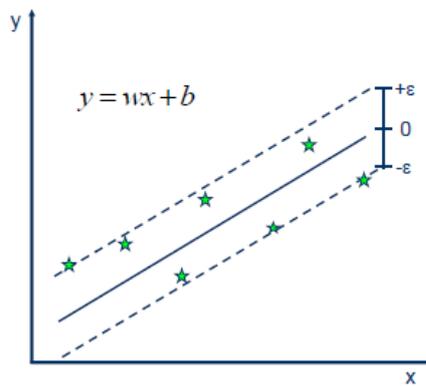


Figura 3.1 - Hiperplanos de separação entre classes

Fonte: (MUELLER, KUSNE; RAMPRASAD; 2016)

Cabe destacar que nem todo hiperplano é linear. O espaço de dimensão superior torna possível a separação linear das partes. Quando ocorre esse mapeamento não linear, são utilizadas as funções de Kernel, justamente para transformá-las em lineares. Resumidamente, esse tipo de função recebe dois pontos dos espaços de entrada e computa o produto escalar desses dados no espaço de características. A simplicidade de cálculo e a sua capacidade de representar espaços abstratos são diferenciais importantes para seu uso nas SVMs. A Figura 3.2 ilustra a transformação gráfica do SVM para SVR para equações mais complexas (SAYAD, 2020).

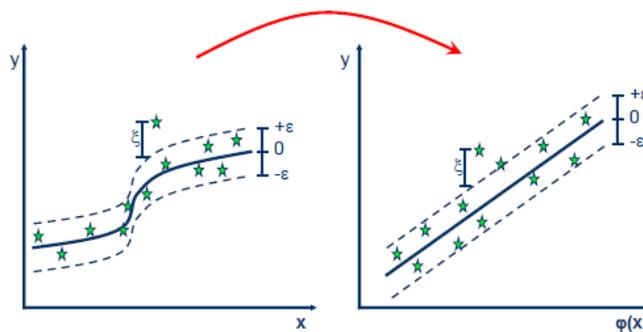


Figura 3.2 - Transformação gráfica do SVM para o SVR em casos de equações não lineares

Fonte: (MUELLER, KUSNE; RAMPRASAD; 2016)

Nesse contexto, investigou-se o uso de SVM para prever a resistência à compressão de concretos auto-adensáveis comparando com a técnica ANN. Os resultados mostram que os modelos aplicáveis com altas qualidades de previsão e normas de generalização são semelhantes, porém o modelo SVM apresentou modelagem mais rápida que modelos NN (SOBHANI, KHANZADI, MOVAHEDIAN; 2013).

### 3.2.2 Redes Neurais Artificiais (ANN)

Uma abordagem intuitiva e efetiva de aplicação de ML é através do cérebro biológico presente nos seres vivos. Essa é a ideia dessa classe de algoritmos de ML denominada Neural Network (NN). Numa rede neural, os neurônios artificiais se agrupam em nós de uma forma que se assemelha as conexões dos neurônios do cérebro necessárias para a realização da sinapse. A Figura 3.3 demonstra uma rede neural artificial e o conceito de perceptron (MUELLER, KUSNE; RAMPRASAD; 2016).

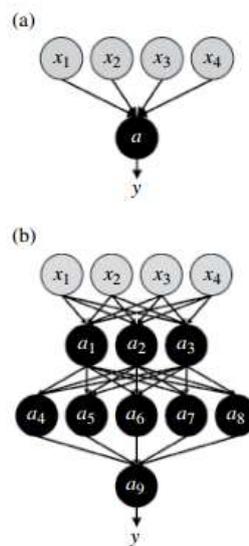


Figura 3.3 – a) Um perceptron. b) Uma rede neural de multicamadas contendo vários nós semelhantes a perceptrons. Os nós que representam variáveis de entrada ( $x_1, x_2, \dots$ ) são cinzas e os nós de funções de ativação ( $a_1, a_2, \dots$ ) são pretos.

Fonte: Mueller, Kusne, Ramprasad (2016)

Os inputs ( $x$ ) são transmitidos diretamente por uma quantidade específica de neurônios da primeira camada neural e eles exercem função de ativação para calcular os outputs que serão usados como inputs para o próximo conglomerado de neurônios. O processo continua até o neurônio que produz o valor de saída final ( $y$ ).

Sabe-se que a rede de NN pode ser simples, de acordo com a Figura 3.3 a, somente com um perceptron, ou nó. A função de ativação nesse caso compara uma soma ponderada de valores de entrada com um valor limite, se a soma for maior que o valor limite, o perceptron produzirá “1” como retorno, caso contrário será retornado o valor “0”.

Existem também NNs mais complexas que combinam diferentes perceptrons em multicamadas. A otimização dos pesos de um perceptron multicamadas é mais complicada do que um simples, mas é possível ser executada com o auxílio de um algoritmo de retropropagação.

Na engenharia de materiais, as redes neurais são utilizadas de forma otimizada há muitos anos, com destaque para a área de potenciais interatômicos precisos e no mapeamento de materiais complexos (tensão de fluxo, comportamento de fadiga, microestrutura, entre outros) para parâmetros de processamento de materiais (tratamento térmico, deformação, entre outros) (MUELLER; KUSNE; RAMPRASAD, 2016).

As redes neurais buscam por padrões e é por isso que os melhores exemplos ocorrem através do ensino das redes neurais. Para ensinar uma rede neural a resolver um determinado problema, deve-se inserir os dados de entrada usando a primeira camada e colocar os dados na camada de saída como um determinado destino para o qual a rede se esforce. Os dados de entrada também podem ser ajustados atribuindo pesos a eles, o que pode representar potencialmente uma determinada variável importante. O mecanismo de controle dos pesos é denominado “regra de aprendizado”. A união dos perceptrons quando combinados passam a atingir resultados interessantes e procuram atingir o valor alvo (ZIOLKOWSKI, NIODOSTATATKIEWICZ, 2019).

### **3.2.3 Perceptron de Múltiplas Camadas (MLP)**

MLP, ou uma rede neural de alimentação direta profunda, é um tipo de ANN (Rede Neural Artificial) que se baseia no sistema neural humano para processar informações. Seu objetivo é aproximar funções de mapeamento entre vetores de entrada e saída.

O MLP é composto por neurônios interconectados em um sistema simples, organizados em pelo menos três camadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (SIDDIQUE, ADELI; 2013), (GOODFELLOW, COURVILLE; 2016). Os neurônios da camada de entrada não realizam cálculos, servindo apenas para transmitir o vetor de entrada para as camadas ocultas. Cada neurônio nas camadas seguintes realiza uma transformação não linear simples, usando uma função de ativação como ReLU, tanh ou sigmoid, para calcular a saída daquela camada. Isso permite que o MLP seja capaz de aproximar funções extremamente não lineares (GARDNER, DORLING; 1998).

Os neurônios em camadas consecutivas são conectados por pesos ( $h$ ) aprendidos durante um processo de treinamento, com o objetivo de aproximar a função de mapeamento dos vetores de entrada para os de saída. O MLP aprende essa função de forma supervisionada (GARDNER, DORLING; 1998), utilizando um conjunto de dados de treinamento. No caso de um problema de regressão, o objetivo do treinamento é aproximar a função  $f$  de modo que o valor derivado de  $f(x_i, h)$  seja próximo ao valor alvo  $y_i$ . A diferença entre os valores derivados e os valores alvo é considerada um sinal de erro. Durante o treinamento, esse sinal de erro é usado para determinar como os pesos ( $h$ ) da rede devem ser ajustados para reduzir o erro geral do MLP.

O treinamento de uma rede MLP é geralmente feito utilizando um processo iterativo baseado em gradientes (RUMELHART; HINTON; WILLIAMS, 1986), como o Descida de Gradiente Estocástico (SGD) ou o método Quasi-Newton, como o Broyden-Fletcher-Goldfarb-Shanno (BFGS) com memória limitada, também conhecido como L-BFGS, para minimizar o erro global. Embora o SGD seja fácil de implementar, otimizá-lo ou treiná-lo pode ser desafiador quando se trabalha com dados esparsos ou problemas de baixa dimensionalidade, como os encontrados em HPC. Nesses casos, o L-BFGS é uma opção altamente competitiva e, às vezes, superior ao SGD (NGIAM ET AL, 2011).

É importante destacar que o treinamento de uma rede MLP não possui garantia de convergência global e é sensível aos valores iniciais dos hiperparâmetros (GOODFELLOW, COURVILLE; 2016), como a função de ativação, o número de camadas ocultas, `hidden_size` (número de neurônios em cada camada), `solver` (método iterativo baseado em gradientes), `max_iter` (número máximo de iterações) e `alpha` (parâmetro de regularização L2). (GOODFELLOW, COURVILLE; 2016).

Desde a década de 1980, as redes neurais têm sido aplicadas a problemas de engenharia civil (CHOU; PHAM, 2013; CHOU; CHONG, 2016). Nos últimos tempos, foram propostos modelos de redes neurais mais poderosos para lidar com dados estruturados (AHMALOU; ADELI, 2010; RAFIEI, ADELI, 2017). No entanto, é importante destacar a importância da afinação dos hiperparâmetros. Por isso, o MLP clássico foi utilizado, a fim de permitir uma comparação com as variantes do MLP propostas anteriormente para os problemas envolvendo concretos (CHOU; CHONG, 2016; NGUYEN *et al.*, 2021)

### 3.2.4 Árvores de Decisão ou Decision Trees (DT)

As Árvores de Decisão ou Decision Trees (DT), são algoritmos de aprendizado de máquina que são normalmente aplicados em problemas que envolvem classificação e utiliza como referência o padrão nos dados. As DT são próximas às NN em relação a sua estrutura uma vez que também é uma rede de nós conectados. Porém, em uma DT a conexão se dá por uma hierarquia semelhante a uma árvore onde cada nó inferior tem somente um nó pai. Alguns dos modelos baseados em DT são M5P-tree, Árvores de múltipla regressão aditiva (MART) e Random Forest (RF) (MUELLER; KUSNE; RAMPRASAD, 2016).

O processo de avaliação da DT começa do nó raiz e flui até os nós sem filhos, denominados nós folha. Ao longo do percurso existem diversos caminhos possíveis, obedecendo a estrutura hierárquica com nós filho diferentes. A escolha de qual ramificação cada nó terá se dá pelo valor de cada uma das variáveis de entrada e o valor de saída é obtido somente ao fim do caminho. DT além de seu uso mais comumente associado a classificação também pode ser usada para regressão, sendo que os nós apresentam valores numéricos distintos (MUELLER, KUSNE; RAMPRASAD, 2016).

Os modelos conhecidos como Random Forest (RF) são uma categoria específica de DT. RF são versões otimizadas, com capacidade de previsão mais potentes. São muito utilizados para tarefas de classificação ou regressão.

Em relação a sua estrutura, RF consistem na combinação de diversas DT diferentes de maneira aleatória, sendo que cada uma é treinada com um Conjunto de Treinamento diferente (HAN *et al.*, 2019). Cada um desses conjuntos é uma subdivisão do Conjunto de Treinamento original de banco de dados e cada um desses conjuntos deve ser dividido aleatoriamente em dados independentes. Cada árvore é treinada de forma individual e posteriormente são repassados novos dados de entrada pelas árvores e os dados de saída são as médias desses valores. (MUELLER, KUSNE e RAMPRASAD; 2016). A Figura 3.4 demonstra esquematicamente, como esse algoritmo funciona.

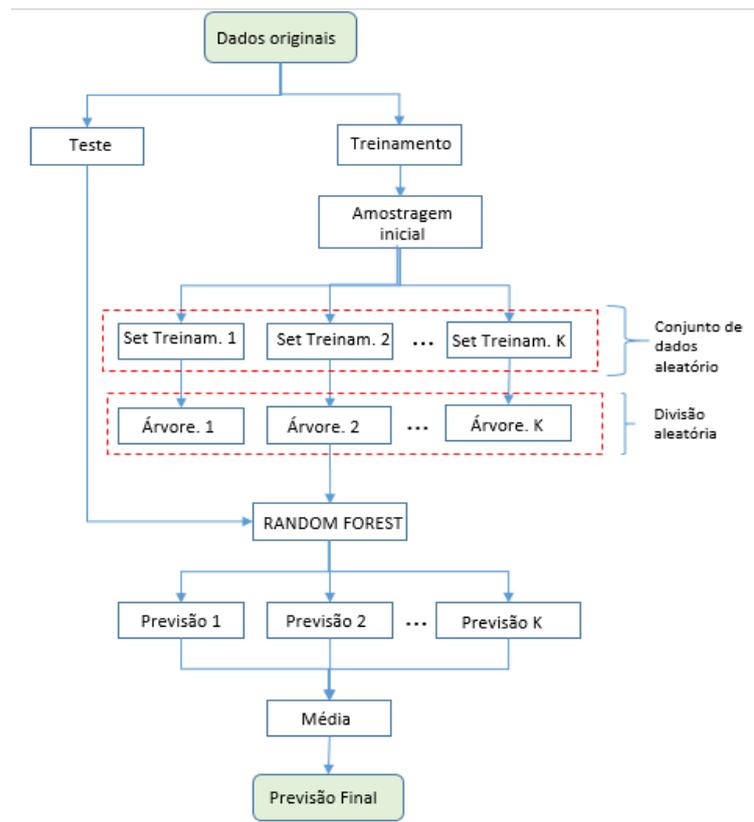


Figura 3.4 - Esquema de Random Forest

Fonte: Adaptado (ZHANG et al, 2019).

### 3.3 MACHINE LEARNING APLICADO A CONCRETOS

Uma literatura básica e essencial para o estudo da predição do comportamento mecânico em concretos foi o de Yeh (1998) que utilizou redes neurais como modelo de algoritmo, estabeleceu inputs relevantes para pesquisas posteriores e forneceu uma matriz de dados com 8 principais dados de entrada, sendo eles: Cimento ( $\text{kg/m}^3$ ); Cinza volante ( $\text{kg/m}^3$ ); Escória de Alto Forno ( $\text{kg/m}^3$ ); Água ( $\text{kg/m}^3$ ); Superplastificante ( $\text{kg/m}^3$ ); Agregado miúdo ( $\text{kg/m}^3$ ); Agregado graúdo ( $\text{kg/m}^3$ ); Idade (dias).

A Figura 3.5, demonstra que o modelo de redes neurais é construído baseado em dados através do domínio experimental. Foi plotada a relação entre os dados de laboratório com os dados obtidos através do algoritmo de aprendizagem de máquina, mostrando que existe uma tendência linear e que quanto maior os parâmetros de resistência maior a dispersão, daí a complexidade da análise para concretos de alto desempenho (YEH, 1998).

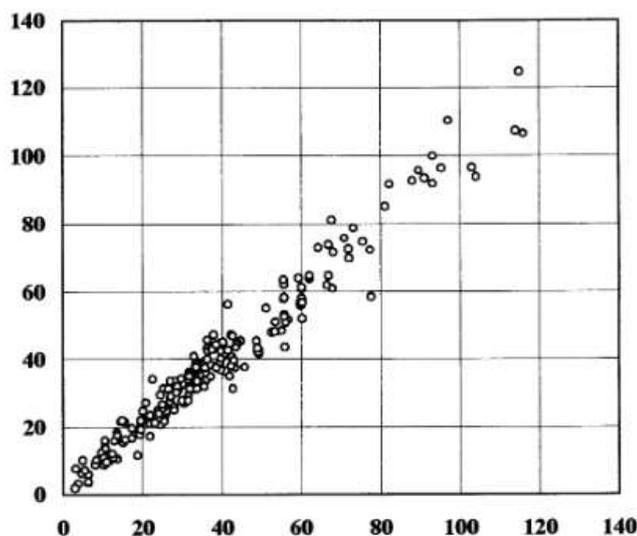


Figura 3.5 - Predição de valores de resistência (em y) utilizando redes neurais comparados com resultados reais testados em laboratórios (em x) em MPa.

Fonte: (Yeh, 1998)

Diversas pesquisas têm aplicado diretamente o uso de ML em vários tipos de concreto específicos. Chaabene, Flah e Nehdi (2020) realizaram uma revisão crítica dos últimos artigos publicados em todo o mundo que abrangem o tema de predição de propriedades mecânicas do concreto utilizando ML e concluiu que algoritmos como ANN e SVM se adequam bem a propostas onde a relação entre os dados não é linear e é afetada por diversos fatores, apresentando menor erro, porém quando se tratam de modelos mais transparentes, DTs e algoritmos evolucionários podem ser aplicados porque eles podem gerar fórmulas matemáticas explícitas que melhor descrevam as relações entre inputs e outputs.

Pesquisas envolvendo concreto autoadensáveis combinados com reforços de fibra utilizam ANN para prever a composição ideal desse concreto através da compilação de dados de literaturas disponíveis nos estados fresco e endurecido (RAMKUMAR; RAJKUMAR; AHMMAD; JEAN, 2020).

Dias, Jayasinghe e Waldmann (2021) investigaram a regressão de processo gaussiana (GPR) com base em um modelo de ML para prever a resistência à compressão do concreto leve Miscanthus. Um banco de dados com 414 dados experimentais, com nove variáveis de entrada seis incluindo os constituintes da mistura, forma do corpo de prova, tempo de cura e condição de pré-tratamento e uma variável de saída: a resistência à compressão. Utilizou-se o Matlab

para implantar o modelo e utilizando o as equações de kernel quadráticas racionais gerou-se erros mínimos na predição: no modelo exponencial um  $R^2$  de 0,917 e no quadrático 0,918.

Kumar et al (2022) também utilizou algoritmos de ML para modelos de predição de resistência a compressão em concretos leves, porém utilizando a Regressão Progressiva Gaussiana (RPG), SVM e Ensemble Learning (EL). Os resultados revelaram que o modelo RPG utilizado teve a melhor acurácia e os modelos SVM e RPG apresentaram boa performance com valores de  $R^2$  0,9777 e 0,9740, respectivamente. Os autores afirmam que o modelo proposto é econômico e eficiente e pode ser adotado por pesquisadores e engenheiros para a predição desse tipo de concreto especial.

Um trabalho recente utilizou algoritmos de aprendizado de máquina supervisionado como Decision Tree (DT), Regressor AdaBoost (AR) para estimar a resistência à compressão de concreto com geopolímeros à base de cinzas volantes. Comparando os dois modelos DT e AR, o último foi mais eficaz na previsão dos resultados pois apresentou menores erros e maiores valores de  $R^2$ , também foi realizada uma análise de sensibilidade para verificação da contribuição de cada parâmetro na análise. Por fim os autores afirmam que a utilização dessas técnicas de ML economiza tempo, esforço e recursos na área da construção civil (AHMAD; AHMAD; ASLAM; JOYKLAD, 2022).

Silva et al (2022) estimou as principais propriedades mecânicas do concreto reforçado com fibras através da previsão de sua resistência à compressão, tração e à flexão utilizando redes neurais. A análise de sensibilidade evidenciou que ocorreu um aumento expressivo nas resistências à tração e à flexão ao utilizar fibras, como já se esperava. As métricas indicadoras da qualidade do ajuste na pesquisa foram para os três parâmetros respectivamente erro quadrático médio (MSE) de 22,63, 0,08, 0,80 e um erro absoluto médio (MAE) de 3,64, 0,24, 0,74. A diferença entre os valores reais e os valores previstos foram, respectivamente: 7,24%, 6,43% e 12,74%, sendo assim a resistência à tração foi a propriedade com valor previsto mais próximo do real.

Várias pesquisas investigaram a previsão da resistência à compressão do concreto com base em proporções de sua mistura, porém o número de amostras na maioria delas, ainda é pequeno para uma boa análise estatística. Dessa forma Young et al (2019) coletaram um conjunto de mais de 10.000 observações de resistências à compressão medidas de misturas reais e outras correspondentes a literatura publicadas por Yeh (1998), comparando os dois dados. Os autores

também realizam projeções de misturas ótimas com o melhor custo-benefício e menor impacto do CO<sub>2</sub> incorporado. Na Figura 3.6 nota-se que não há uma relação clara e direta entre cada um dos dados de entrada com os dados de saída da resistência a compressão.

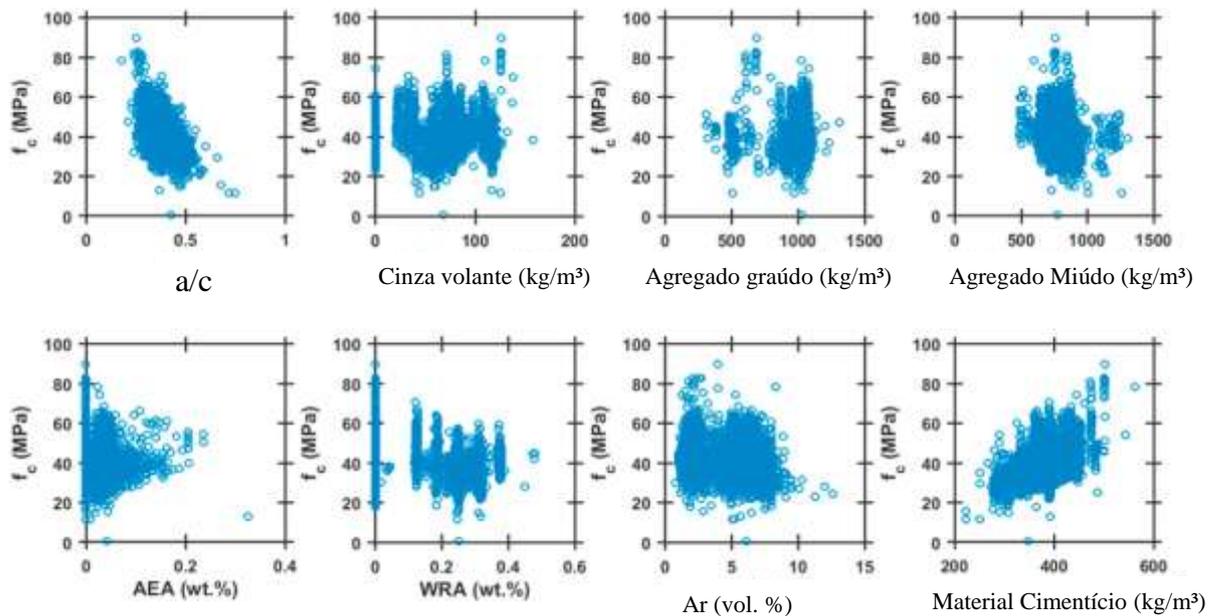


Figura 3.6 - A relação entre as oito variáveis de entrada e a resistência à compressão do concreto no conjunto de dados bibliográficos.

Fonte: Young et al (2019).

Dessa forma, percebe-se a importância da análise dos parâmetros de entrada (inputs) para a determinação e previsão dos dados de saída (outputs), da compreensão dos dados estatísticos para a análise nos algoritmos de ML e por fim da sua aplicabilidade prática em diferentes tipos de concretos.

Na pesquisa de Yeh (1998) os inputs utilizados foram os seguintes, com suas devidas justificativas:

- Água: sabe-se que para uma mistura padrão quanto menor a relação água/cimento de um concreto, o resultado de resistência mecânica a compressão tende a ser maior, sendo, portanto, inversamente proporcional. (L/m<sup>3</sup> ou kg/m<sup>3</sup>)
- Quantidade de cimento: propriedades específicas do tipo de cimento e outras propriedades diretamente ligadas a ele irão influenciar na consistência e na resistência mecânica do concreto como: concentração de óxidos, superfície específica Blaine, em m<sup>2</sup>/kg, dentre outros.

- Agregados miúdos e graúdos: é o parâmetro que estabelece a quantidade desses agregados, podendo ser fornecido tanto em massa quanto volume, neste caso será atribuído em  $\text{kg/m}^3$ .
- Escória de alto forno: parâmetro que pode reduzir as emissões de  $\text{CO}_2$  na produção do cimento, além de influenciar em parâmetros de resistência a depender de sua quantidade. É dada em  $\text{kg/m}^3$ .
- Cinzas Volantes: é um material que pode apresentar atividade pozolânica alta, influenciando no concreto no estado fresco e na sua resistência à compressão. Esse parâmetro também é fornecido em  $\text{kg/m}^3$ .
- Aditivos: o tipo e teor de aditivos químicos influenciará diretamente na consistência e consequentemente na trabalhabilidade, alterando a relação água/cimento e a mistura como um todo.
- Idade: apresentada em dias, refere-se diretamente ao tempo correspondente após cura em que o corpo de prova foi submetido ao ensaio de resistência à compressão.

Alguns estudos (DABIRI *et al.*, 2022; MYLVAGANAM; YOGARAJAH, 2023) comprovam que a resistência à compressão do concreto pode estar diretamente relacionada à relação água/cimento, uma vez que quanto maior esse fator, menor é a resistência observada. No entanto, observa-se que essa relação não é o único fator relevante na resistência à compressão. Outros elementos como as propriedades do cimento, distribuição do tamanho das partículas dos agregados, proporções da mistura, aditivos químicos e materiais cimentícios suplementares (como cinzas volantes e escória) também podem influenciar essa propriedade.

Numerosos estudos têm se esforçado para desenvolver modelos capazes de prever a resistência à compressão de materiais como cimento, argamassa e concreto. Esses modelos utilizam diferentes metodologias e fontes de dados, como técnicas estatísticas, análises analíticas, cálculos matemáticos, simulações numéricas e algoritmos computacionais (HOANG, 2022).

Pesquisadores (YEH, 1998; YEH, 1999; GUPTA, 2013) começaram a utilizar técnicas de Aprendizado de Máquina (ML) para estimar a resistência à compressão do concreto, demonstrando suas altas capacidades de resolução de problemas na indústria da construção, incluindo gerenciamento de qualidade, otimização de projetos, mecânica de fratura, monitoramento estrutural e análise de riscos.

ML, que é um subcampo da Inteligência Artificial (IA), trabalha com algoritmos que permitem que computadores aprendam a partir de um banco de dados específico (YEAH, 2003). Vale ressaltar que muitos estudos têm sido realizados para prever a resistência à compressão usando técnicas de AM em concretos especiais, como aqueles de ultra-alta resistência. Esses estudos exigem estudos de dosagem de materiais mais rigorosos, levando a relações não-lineares complexas (YEH, 2006). Além disso, esses modelos são estabelecidos dividindo os dados de entrada em conjuntos de treinamento, teste e validação. Durante a fase de treinamento, o modelo aprende autonomamente os principais padrões dos dados. O conjunto de validação ajuda a confirmar os resultados previstos durante o treinamento e, eventualmente, durante a etapa de teste ou quando novos dados não incluídos no conjunto de treinamento são introduzidos. Essa etapa é usada para avaliar o desempenho do modelo desenvolvido (GUPTA, 2013).

A técnica de Rede Neural Artificial (ANN) é uma das mais utilizadas para prever a resistência à compressão do concreto. A primeira camada do algoritmo é composta pelos dados de entrada, que geram um retorno de dados de saída. Vários fatores que influenciam a resistência à compressão do concreto são usados como variáveis de entrada nesses estudos (ASTERIS; MOKO, 2019).

Diferentes fatores que influenciam a resistência à compressão do concreto são utilizados como inputs nesses estudos (YEH, 2003) (YEH, 2006). Xu *et al.* (2023) utilizaram variáveis como relação água/cimento, tamanho máximo do agregado e relação agregado/cimento em um estudo sobre concreto incorporando agregado reciclado, por exemplo. Além disso, Yeh (2006) investigou o uso potencial de experimentos e modelagem com redes neurais para determinar o efeito de substituições de cinzas volantes, de 0 a 50%, na resistência à compressão tardia, de 3 a 56 dias, de concretos de baixa e alta resistência. O estudo concluiu que redes neurais, após o treinamento, podem ajudar a verificar quais componentes contribuem mais para a obtenção de maior resistência e sugerir que misturas com teores mais elevados produzam razões de resistência mais baixas em um período tardio.

Desde algum tempo, o uso de redes neurais artificiais tem sido considerado também no caso do concreto armado. Isso inclui o estudo de Amani e Moeini (2012) sobre a capacidade de cisalhamento de vigas de concreto armado por meio de redes neurais artificiais (ANN) e sistema de inferência neurofuzzy adaptativo (ANFIS). Eles concluíram que a ANN teve um desempenho melhor utilizando o algoritmo MLP/BP do que o modelo ANFIS.

Em outro estudo, Behnood et al. (2015) consideraram 4 parâmetros como modelo (relação água/cimento, resistência à compressão do concreto, idade do espécime e índice de reforço com fibras de aço) para prever a resistência à tração do concreto reforçado com fibras de aço. Eles utilizaram o método ANN e relataram um melhor desempenho em comparação com o SVM. Kumar e Barai (2010) também avaliaram a resistência ao cisalhamento de consoles de concreto reforçado com fibras de aço sem reforço de cisalhamento e os testaram sob carga vertical usando BPNN, concluindo a alta precisão do modelo.

Por outro lado, o estudo de Altun *et al.* (2008) examinou a resistência à compressão de concreto leve reforçado com fibras de aço utilizando os métodos ANN e MLR, relatando um melhor desempenho do modelo ANN. Perera *et al.* (2010) e Tanarslan *et al.* (2012) também estudaram a resistência ao cisalhamento de vigas de concreto reforçado com PRF em seu estudo usando uma rede neural artificial. Eles relataram um melhor desempenho de BPNN em comparação com as equações experimentais.

Aiticin (2011) ao estudar a resistência à compressão de concreto contendo diferentes quantidades de escória de alto-forno e cinza volante, concluiu o desempenho aceitável de BPNN em comparação com a regressão múltipla. Nikoo *et al.* (2015) também avaliaram a resistência à compressão de concreto contendo escória de alto-forno e cinza volante usando um algoritmo genético para otimizar a rede neural artificial. Os resultados da simulação mostraram que o modelo ANN possui mais flexibilidade, capacidade e precisão na previsão da resistência à compressão do concreto. O estudo de Ozcan *et al.* (2009) comparou redes neurais artificiais e lógica difusa para prever a resistência à compressão do concreto contendo sílica ativa. Eles relataram a eficácia de ambos os métodos e também relataram a superioridade do método ANN sobre o método FL após a comparação do  $R^2$  (MOEIN *et al.*, 2023).

Uma revisão de vários estudos mostra que a relação entre componentes de concreto e resistência mecânica é influente na escolha do modelo de previsão. Portanto, modelos que podem responder em espaço não linear devem ser usados se a relação for não linear. Nesses casos, os modelos SVM e ANN podem ser usados por seu desempenho aceitável em um ambiente não linear com menos erros. Para obter resultados mais precisos, também pode ser utilizada a otimização desses modelos com algoritmos metaheurísticos, ou seja, de alta complexidade onde algoritmos convencionais não apresentam resultados satisfatórios. (MOEIN *et al.*, 2023)

Mas se precisarmos da transparência do modelo e da fórmula matemática explícita entre entrada e saída, podemos usar modelos de árvore de decisão e algoritmos evolutivos. Por outro lado, o uso de modelos ensemble para otimizar esses modelos, embora resulte em maior precisão, aumenta o tempo de computação e a complexidade do modelo. Os modelos combinados SVM e ANN, embora aumentem o tempo de computação, apresentam resultados precisos diante de dados extensos.

Para sintetizar a análise de erros em uma modelagem utilizando redes neurais artificiais para a previsão da resistência à compressão de concretos, diferentes autores utilizam parâmetros de erros, como os destacados na Tabela 3.1, dividindo-se entre treinamento e teste os resultados de  $R^2$ , MSE e RMSE de cada pesquisa.

| Autor           | Ano da Publicação | Estudo  | Algoritmos Adotados | Parâmetros de Treinamento |     |       | Parâmetros de Teste |        |       |
|-----------------|-------------------|---|---------------------|---------------------------|-----|-------|---------------------|--------|-------|
|                 |                   |   |                     | $R^2$                     | MSE | RMSE  | $R^2$               | MSE    | RMSE  |
| Feng et al      | 2020              | Concreto Convencional                           | Adaboost            |                           |     |       | 0,982               | 11,610 | 2,200 |
| Paudel et al    | 2023              | Concreto com Cinza Volante                      | Multiple LR         |                           |     |       | 0,520               | 88,430 | 9,400 |
| Paudel et al    | 2023              |   | SVR                 |                           |     |       | 0,850               | 27,060 | 5,200 |
| Paudel et al    | 2023              |   | Adaboost            |                           |     |       | 0,890               | 20,000 | 4,470 |
| Paudel et al    | 2023              |   | Bagging             |                           |     |       | 0,910               | 16,630 | 4,078 |
| Paudel et al    | 2023              |   | Random Forest       |                           |     |       | 0,910               | 15,990 | 3,990 |
| Asteris e Mokos | 2020              | Concreto Convencional (métodos não destrutivos) | ANN                 | 0,960                     |     | 2,866 | 0,960               |        | 4,367 |
| Asteris e Mokos | 2020              |   | ANN                 | 0,988                     |     | 2,732 | 0,905               |        | 4,327 |
| Asteris e Mokos | 2020              |   | ANN                 | 0,988                     |     | 1,548 | 0,987               |        | 1,685 |
| Asteris e Mokos | 2020              |   | ANN                 | 0,991                     |     | 1,328 | 0,983               |        | 1,681 |
| Asteris e Mokos | 2020              |   | ANN                 | 0,993                     |     | 1,187 | 0,982               |        | 1,934 |
| Asteris e Mokos | 2020              |   | ANN                 | 0,994                     |     | 1,109 | 0,980               |        | 0,941 |

Tabela 3.1 Resumo de Parâmetros de Treinamento e Teste em Pesquisas Acadêmicas

Fonte: Próprio Autor, 2023

Para esses estudos com diferentes algoritmos adotados observa-se uma variação de 0,850 até 0,980 para o  $R^2$ , de 11,61 até 88,430 para MSE e de 0,941 até 9,400 para RMSE. Esses parâmetros de erro informam o quão bem o algoritmo efetivamente conseguiu prever os dados de acordo com os diferentes dados de entrada utilizados (FENG *et al.*, 2020; PAUDEL *et al.*, 2023; ASTERIS e MOKOS, 2020).

Flah e Nehdi (2020) investigaram quais os principais parâmetros de entrada (inputs) para dois diferentes tipos de concreto: Concreto de Alto Desempenho e Concreto utilizando agregados recicláveis. A Figura 3.7 exemplifica como os componentes do concreto convencional junto com o consumo de materiais cimentícios suplementares representam mais de 75% de

representação nas pesquisas. A principal mudança ao se analisar concretos com agregados recicláveis são parâmetros relativos ao consumo e características físicas dos agregados que estão presentes em 40% das pesquisas.



Figura 3.7 Parâmetros de entrada utilizados para modelos ML para prever a resistência à compressão para concretos de alto desempenho.

Fonte: Flah e Nehdi, 2020 (adaptado)

Portanto, com base no estudo, em termos de ciência concreta, estudos limitados foram conduzidos no campo de identificação das capacidades de concreto geopolímero, compósito cimentício de engenharia, concreto auto-regenerativo, concreto nanocontido e concreto autoadensável, que os pesquisadores podem examinar em estudos futuros. A depender do tipo específico do concreto analisado diferentes parâmetros de entrada devem ser utilizados de forma a melhorar e caracterizar o comportamento da resistência à compressão. (MOEIN *et al.* 2023).

### 3.4 PRINCIPAIS DESAFIOS DE ANÁLISE DE DADOS COM ML

Os modelos de aprendizado de máquina (ML) requerem dados para aprender padrões e relacionamentos e, em seguida, generalizar essas tendências para uma população maior. A qualidade desses dados (ou seja, sua representatividade, completude e correção) é de extrema importância para o desempenho e validade do modelo (SOBHANI.; KHANZADI; MOVAHEDIAN, 2013).

A coleta e curadoria de conjuntos de dados extensos são fundamentais para o ML. No entanto, a coleta de dados é especialmente árdua e demorada no domínio da ciência do concreto, onde várias amostras precisam ser moldadas e testadas após uma longa duração de cura (tipicamente 28 dias para aplicações de engenharia e até vários anos para estudos de durabilidade). (SOBHANI.; KHANZADI; MOVAHEDIAN, 2013).

Embora centenas de milhares de misturas de concreto e suas propriedades correspondentes tenham sido relatadas na literatura nas últimas décadas, é desafiador coletar e organizar esses dados experimentais de maneira sistemática. Formatos de relatórios diferentes (por exemplo, como texto ou em figuras, tabelas e esquemas) e parâmetros experimentais diferentes (por exemplo, tipo e quantidade de constituintes individuais) são usados na literatura e nem todos os resultados experimentais são relatados com o mesmo nível de completude. (PARK et al, 2021)

Como resultado, os conjuntos de dados usados na pesquisa do concreto baseada em ML tendem a ser pequenos. A falta de um conjunto de dados suficientemente grande aumenta o risco de superajuste. Um conjunto de dados pequeno, mas potencialmente complexo, pode impedir que os modelos de ML produzam resultados precisos e generalizáveis. (PARK et al, 2021).

Misturar duas bases de dados para treinamento e teste usando o algoritmo de Perceptron de Múltiplas Camadas (também conhecido como MLP - Multi-Layer Perceptron) pode ser uma abordagem válida em certos casos, mas é importante considerar algumas questões antes de fazê-lo. Alguns deles são:

- Tamanho e representatividade das bases de dados: Se as duas bases de dados são grandes, representativas e têm domínios de dados semelhantes, combiná-las pode aumentar a diversidade dos exemplos de treinamento e melhorar a generalização do modelo. No entanto, se uma das bases de dados for muito menor ou menos

representativa, isso pode levar a um desequilíbrio de classes, o que pode prejudicar o desempenho do modelo.

- **Consistência das características:** As bases de dados devem ter características (atributos) que são consistentes entre si. Se houver diferenças significativas nas características entre as bases de dados, o modelo pode ter dificuldade em generalizar corretamente, prejudicando o desempenho.
- **Distribuição dos dados:** É essencial verificar se a distribuição dos dados é semelhante entre as duas bases de dados. Se houver uma diferença significativa na distribuição, o modelo pode aprender tendências específicas de uma base e não ser capaz de lidar com dados da outra base.
- **Separação de treinamento e teste:** Mesmo que você misture as bases de dados para treinamento, é importante manter conjuntos de teste separados para avaliar o desempenho real do modelo. Isso ajuda a garantir que o modelo generalizou bem para novos dados.
- **Pré-processamento e normalização:** Ao combinar bases de dados, o pré-processamento e a normalização dos dados são fundamentais para garantir que eles estejam em escalas semelhantes e que não haja viés para uma base em detrimento da outra.
- **Validação cruzada:** Para avaliar melhor o desempenho do modelo e garantir resultados mais robustos, é recomendado o uso de validação cruzada, que envolve dividir os dados em vários conjuntos de treinamento e teste para obter métricas mais confiáveis.
- **Experimentação e comparação:** Antes de tomar uma decisão final, é essencial realizar experimentos e comparar o desempenho do modelo usando diferentes combinações de bases de dados para verificar se a mistura melhora os resultados.

Em resumo, utilizar duas bases de dados pode ser uma opção viável se as bases forem semelhantes em termos de tamanho, representatividade, distribuição e características. Contudo, é crucial realizar uma análise cuidadosa dos dados e realizar experimentos para garantir que a abordagem de mistura das bases de dados melhore o desempenho do algoritmo MLP em relação a outras abordagens.

O objetivo principal deste estudo é prever a resistência à compressão de concretos e comparar os resultados entre um banco de dados nacional construído por meio de publicações em

congressos e trabalhos acadêmicos com um banco de dados de referência usando a técnica de Machine Learning ANN. O estudo também visa verificar as variações dos resultados quando o banco de dados nacional e o banco de dados de referência são alternados como conjunto de treinamento e teste.

## 4 METODOLOGIA

O objetivo da investigação é a utilização de ML para a previsão da resistência à compressão de concretos através da comparação de duas bases de dados. Para a realização da pesquisa o Concreto Referência (CR), ou padrão, foi escolhido pelo fato de ser o compósito mais simples possível e não possuir materiais cimentícios suplementares (MCS) adicionados além da proporção estabelecida na NBR 16697 (ABNT, 2018) nos cimentos. O Fluxograma da pesquisa está descrito na Figura 4.1.

Dessa forma, para maiores esclarecimentos denomina-se CR como o concreto composto por cimento, agregado miúdo e gráudo natural ou artificial, aditivos químicos e água. Assim, somente são considerados os materiais cimentícios suplementares já presentes nos cimentos brasileiros.

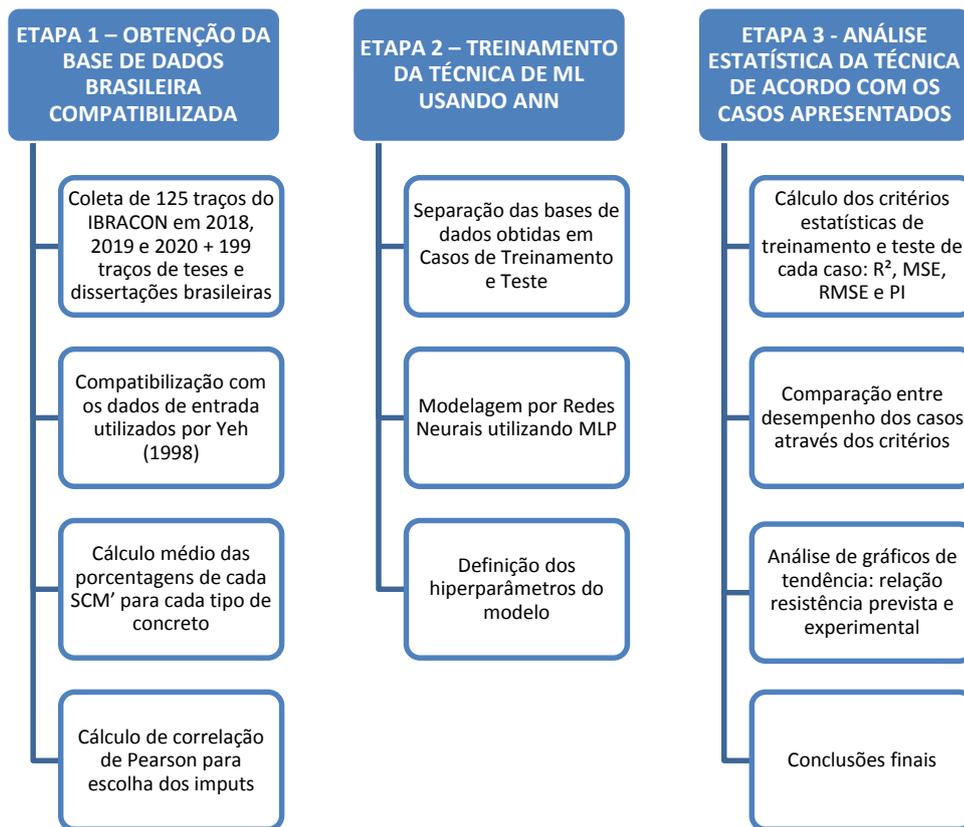


Figura 4.1 - Fluxograma de pesquisa

Fonte: Próprio Autor, 2023

De forma simplificada, foram realizadas a seleção de dados, pré-processamento, transformação, mineração, análise e assimilação dos resultados na Etapa 1.

Na Etapa 2 ocorreu o treinamento e teste através de redes neurais utilizando Perceptron de Múltiplas Camadas e na Etapa 3 os parâmetros  $R^2$ , MSE, RMSE que demonstram o desempenho do modelo são detalhados para cada um dos casos classificados.

#### **4.1 ETAPA 1 – OBTENÇÃO DA BASE DE DADOS BRASILEIRA COMPATIBILIZADA**

A Etapa 1 consiste na elaboração do banco de dados através dos dados de entrada apresentados na Tabela 4.1. Para isso foram realizados: a seleção de dados, pré-processamento, transformação, mineração, análise e assimilação dos resultados

A seleção de dados envolve a escolha de conjuntos de dados relevantes e representativos, que podem ser obtidos a partir de fontes públicas, dados de campo ou internos. O pré-processamento dos dados é realizado para limpar e preparar os dados brutos, removendo valores ausentes, tratando outliers e normalizando as variáveis. Isso garante a qualidade dos dados e melhora a eficácia dos modelos.

Após o pré-processamento, a transformação dos dados é realizada, onde os dados são ajustados para atender às necessidades do modelo de predição. Isso pode envolver a codificação de variáveis categóricas, redução de dimensionalidade ou transformação de variáveis para atender a suposições dos modelos. Em seguida, ocorre a de mineração de dados, onde são aplicados algoritmos de aprendizado de máquina ou técnicas de mineração de padrões para desenvolver o modelo de predição da resistência à compressão em concretos. Esses algoritmos são treinados usando os conjuntos de dados preparados anteriormente, buscando encontrar relações e padrões relevantes.

Cada traço representa uma linha de código na matriz piloto e eles foram obtidos através de trabalhos de conclusão de curso, dissertações e teses em universidades públicas e privadas brasileiras. Além disso, utilizou-se dos anais publicados nos dois últimos congressos do IBRACON (Instituto Brasileiro do Concreto) referentes a 2019 e 2020, sendo este último realizado no ano de 2021 devido à crise sanitária do COVID-19 no ano anterior.

| Dados de Entrada |  | Dados de saída                 |
|------------------|--|--------------------------------|
| Inputs           |  |                                |
| 1                | Cimento (kg/m <sup>3</sup> )               | Resistência a compressão (MPa) |
| 2                | Escória de alto forno (kg/m <sup>3</sup> ) |                                |
| 3                | Cinza Volante (kg/m <sup>3</sup> )         |                                |
| 4                | Agregado miúdo (kg/m <sup>3</sup> )        |                                |
| 5                | Agregado graúdo (kg/m <sup>3</sup> )       |                                |
| 6                | Água (kg/m <sup>3</sup> )                  |                                |
| 7                | Superplastificante (kg/m <sup>3</sup> )    |                                |
| 8                | Idade (dias)                               |                                |

Tabela 4.1 - Inputs e Outputs

Fonte: Próprio Autor, 2023

Utilizaram-se duas bases de dados para o estudo sobre a análise dos efeitos dos parâmetros de dosagem de concreto na resistência. O primeiro conjunto de dados, DATA\_YEH98, foi obtido do banco de dados Yeh (1998), que está disponível gratuitamente no repositório UC Irvine Machine Learning e contém 1030 instâncias para análise de diferentes algoritmos de aprendizado de máquina. Esses dados foram calculados e analisados usando parâmetros estatísticos e numéricos. Os dados de entrada (*inputs*) incluíam Cimento (kg/m<sup>3</sup>), Pozolana (kg/m<sup>3</sup>), Água (kg/m<sup>3</sup>), Agregado Grosso (kg/m<sup>3</sup>), Agregado Fino (kg/m<sup>3</sup>), Idade (dias) e Resistência (MPa), sendo a saída a Resistência Predita (MPa). Este conjunto de dados será denominado como DATA\_YEH98.

O segundo banco de dados foi construído pelo autor e baseou-se nos mesmos dados de entrada, mas para concretos brasileiros obtidos na literatura, com foco em teses, dissertações e artigos nacionais (DATA\_BR23). Foram coletados 197 traços de trabalhos acadêmicos brasileiros sendo aproximadamente 78% deles provenientes do Congresso do IBRACON, cada um desses traços possui duas instâncias, totalizando um máximo de 332 instâncias (definição). Instância pode ser definida nessa pesquisa como o conjunto de dados incluindo os inputs e as resistências à compressão referentes a idade de cura do concreto para cada idade coletada. O output, como camada de saída, foi a resistência à compressão, em MPa.

No total, 324 instâncias distintas foram selecionadas para análise, com mais de 70% retiradas de artigos publicados em congressos do IBRACON (Instituto Brasileiro do Concreto) em 2018,

2019 e 2020. Aproximadamente 18% são anteriores à 2017; 34% foram publicadas em 2018, 21% em 2019, 20% em 2020, 6% em 2021 e 1% em 2022.

Para a obtenção de DATA\_BR23 foram selecionados traços de concreto referência ou padrão das pesquisas. O termo "concreto referência" é usado para se referir a uma formulação do concreto adotada como padrão em cada pesquisa na área de engenharia civil. Essa formulação é considerada uma referência para comparação e avaliação de propriedades do concreto em diferentes estudos.

O concreto referência, neste caso, não possui uma composição fixa e pré-determinada de materiais, como cimento, agregados (miúdos e grãos), água e, em alguns casos, aditivos. As proporções e características desses materiais são escolhidas com base em padrões de componentes e normas estabelecidos por organizações técnicas e de padronização.

A escolha de um concreto referência ocorre porque é importante ter uma base comparativa padronizada para avaliar o desempenho e as propriedades de diferentes misturas de concreto. Usar um concreto de referência permite que os pesquisadores comparem os resultados de seus experimentos e estudos de maneira consistente, identificando variações e diferenças significativas em relação ao padrão estabelecido.

O uso de um concreto referência também facilita a replicação de resultados e a comparação entre diferentes estudos, o que contribui para o avanço do conhecimento na área e aprimoramento das técnicas de projeto e construção de estruturas de concreto.

É importante observar que o concreto referência pode variar dependendo do contexto e do objetivo da pesquisa. Existem várias formulações de concreto de referência utilizadas em diferentes países e setores da indústria, cada uma com suas próprias características e propriedades específicas. Apesar dessa variação, para esta pesquisa, foram coletados somente concretos sem outros materiais cimentícios suplementares, além daqueles já presentes nos cimentos brasileiros.

A próxima fase da Etapa 1 se baseou no cálculo para a estimativa das quantidades dos compostos do cimento: Clínquer + silicato de cálcio, pozolana, escória de alto forno e fíler ou material carbonático. Isso foi necessário, visto que como existem dados de diversos tipos de cimentos distintos para que possa haver uma comparação com a base de dados de Yeh (1998),

uma das principais referências internacionais de ML em concretos, deve-se padronizar os mesmos dados de entrada. Dessa forma a matriz principal contém a dosagem unitária dos concretos, além do consumo de cada um dos materiais utilizados e por fim o parâmetro de saída para a realização dos treinamentos e testes posteriormente.

Os dados disponíveis no repositório estão divididos em 7 componentes, todos em kg/m<sup>3</sup>: cimento, escória, cinzas volantes, água, superplastificante, agregado graúdo e agregado miúdo. No entanto, os dados de dosagem de concreto no Brasil costumam ser apresentados de forma unitária, como 1:a:p, indicando uma parte de cimento para uma parte “a” de agregado miúdo e “p” de agregado graúdo. Para estimar a quantidade de cada componente no concreto, foi utilizado o consumo de cimento como referência, juntamente com uma estimativa média de materiais cimentícios suplementares, uma vez que esses componentes variam de acordo com o tipo de cimento utilizado.

Um ajuste foi necessário, pois os cimentos brasileiros podem ter limites específicos para clínquer com sulfato de cálcio (equivalente aos dados de entrada para cimento), escória, pozolana e fíler calcário. Para garantir que os parâmetros de análise fossem os mesmos do banco de dados do repositório, foi alcançada compatibilidade de acordo com o ano de publicação e a norma brasileira em vigor naquele momento. A entrada "Cinzas Volantes" foi substituída por "Pozolana", uma vez que as normas brasileiras utilizam esse termo mais geral para estimar a composição do cimento. A norma NBR 16697 (ABNT, 2018) foi utilizada a partir de 2018, enquanto as normas NBR 11578, NBR 5735 e NBR 5733 foram utilizadas nos períodos anteriores. Foram importantes a inserção de dados mais antigos para aumentar o banco de dados. A Tabela 4.2 mostra os valores percentuais considerados após e antes de 2018, respectivamente.

| <b>Valores médios adotados - NBR 16697 (Depois 2018/Antes)</b> |                          |                |                 |              |              |
|--|--------------------------|----------------|-----------------|--------------|--------------|
|  | <b>Clinker+ Silicato</b> | <b>Escória</b> | <b>Pozolana</b> | <b>Fíler</b> | <b>Total</b> |
| CP II E  | 72.5/75%                 | 20.0%          | 0.0%            | 7.5/5.0%     | 100.0%       |
| CP II Z  | 82.5/85%                 | 0.0%           | 10.0%           | 7.5/5.0%     | 100.0%       |
| CP II F  | 82.0/92%                 | 0.0%           | 0.0%            | 18.0/8.0%    | 100.0%       |
| CP III   | 45.0%                    | 50.0/52.5%     | 0.0%            | 5.0/2.5%     | 100.0%       |
| CP IV  | 65.0%                    | 0.0%           | 30.0/30.2%      | 5.0/2.5%     | 100.0%       |
| CP V ARI   | 90.0/97.5%               | 0.0%           | 0.00%           | 10.0/2.5%    | 100.0%       |

Tabela 4.2- Valores médios adotados - NBR 16697

Os dados para cada um dos componentes acima foram estimados com base na média aritmética simples. Esta Etapa 1 corresponde à etapa de Mineração de Dados obtida para o banco de dados nacional. Em resumo, esta é a etapa essencial para construir o banco de dados que será modelado posteriormente.

## **4.2 ETAPA 2 - TREINAMENTO DA TÉCNICA DE ML USANDO ANN**

Um processo padrão para treinamento, validação e teste de redes neurais artificiais envolve etapas específicas. A primeira etapa é a preparação dos dados, que envolve organizar e ajustar os dados para uso na rede neural. Isso inclui atividades como normalização, imputação de valores ausentes e separação dos dados em conjuntos de treinamento e teste (NUNEZ *et al.*, 2021).

Em seguida, é realizada a etapa de treinamento da rede neural, em que o conjunto de treinamento é usado para ajustar os pesos e camadas da rede, de modo que as saídas previstas estejam próximas dos valores reais. Posteriormente, é executada a etapa de teste da rede, em que o conjunto de teste é usado para avaliar a precisão da rede neural treinada. Isso é feito comparando as saídas previstas com os valores reais dos dados de teste (YEH, 1998).

Com base no exemplo com polinômios discutido por Shalizi (ERIC, 2006), pode-se argumentar que os modelos devem encontrar um equilíbrio entre situações de subajuste e sobreajuste. No caso do sobreajuste, o modelo se ajusta excessivamente aos dados de treinamento, mas não apresenta boa generalização. Por outro lado, o subajuste ocorre quando o modelo é muito simplista para o conjunto de dados, falhando em capturar os padrões subjacentes e apresentando uma má generalização.

Para evitar essas situações mencionadas, é crucial medir os erros de previsão tanto para os dados de treinamento quanto para os dados não observados, engajando-se em um processo chamado validação. Nesse sentido, técnicas de validação cruzada entram em jogo, utilizando os próprios dados de treinamento para fins de validação. Ao empregar essa abordagem, não há redução no conjunto de treinamento, e não é necessário adquirir dados adicionais exclusivamente para

validação. Esses aspectos têm um valor significativo, pois a aquisição de dados é uma empreitada custosa, exigindo tempo, esforço, recursos financeiros, organização e expertise. Como afirmado por Shalizi (ERIC, 2006), "adquirir um conjunto de validação é caro".

Além disso, é importante enfatizar que mesmo para problemas simples de Aprendizado de Máquina (GÉRON, 2019), milhares de exemplos são necessários. Assim, o uso de técnicas de validação cruzada, que permitem uma avaliação precisa do desempenho do modelo sem a necessidade de dados adicionais, prova ser altamente vantajoso no campo da construção civil e em outros domínios que enfrentam desafios relacionados à coleta de dados. Nesta pesquisa, foi utilizada a validação cruzada com k-fold e 10 partições.

Se a precisão da rede não for satisfatória, ajustes na arquitetura da rede ou nos parâmetros de treinamento podem ser feitos, e o processo de treinamento e teste pode ser repetido. Por fim, quando a precisão for satisfatória, a rede neural pode ser usada para fazer previsões com novos dados. O objetivo final desse processo é ajustar a rede neural para que ela possa fazer previsões precisas com dados novos e desconhecidos.

Muitos treinamentos preditivos utilizam a Regressão Linear (LR), um algoritmo supervisionado de Aprendizado de Máquina que utiliza dados históricos conhecidos para prever comportamentos. Esse modelo é amplamente aplicável, o que justifica seu uso frequente e estabelece uma relação entre a variável dependente e a variável independente.

Para uma análise dos dados de treinamento e teste, neste artigo, optou-se pela metodologia de dividir os dados em 5 casos principais, conforme simplificado na Tabela 4.3 e Figura 4.2.

| <b>Caso</b> | <b>Treinamento</b> | <b>Teste</b> | <b>Acrônimo</b> |
|-------------|--------------------|--------------|-----------------|
| <b>1</b>    | DATA_BR23          | DATA_BR23    | TR_TE.BR        |
| <b>2</b>    | DATA_YEH98         | DATA_YEH98   | TR_TE.YEH       |
| <b>3</b>    | DATA_YEH98         | DATA_BR23    | TR.YEH_TE.BR    |
| <b>4</b>    | DATA_BR23          | DATA_YEH98   | TR.BR_TE.YEH    |
| <b>5</b>    | ALL                | ALL          | TR_TE.ALL       |

Tabela 4.3 - Acrônimos dos casos

Fonte: Próprio Autor, 2023

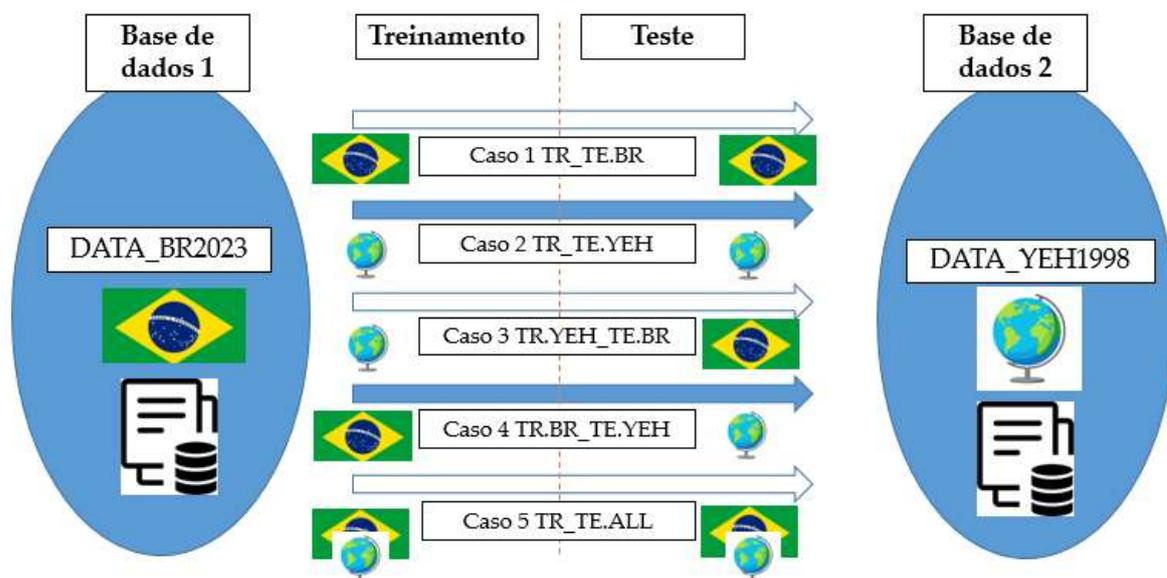


Figura 4.2 - Bases de dados utilizadas em cada caso para treinamento e teste

Fonte: Próprio Autor, 2023

Nos casos 1, 2 e 5, 80% das amostras foram utilizadas para treinamento e 20% para teste, enquanto nos casos 3 e 4 foram utilizadas 100% das amostras. Essa decisão foi tomada especificamente para esta pesquisa devido ao fato de que um modelo de Aprendizado de Máquina não pode ser testado com dados que ele já viu na fase de treinamento. Portanto, nos casos 3 e 4, todos os dados podem ser usados, uma vez que os conjuntos de treinamento e teste utilizam bancos de dados diferentes.

O treinamento foi realizado utilizando a linguagem de programação Python, amplamente empregada em aplicações de Aprendizado de Máquina. Proficiência em programação é crucial para uma análise de dados eficaz. Habilidades de programação capacitam pesquisadores e analistas a manipular, pré-processar e transformar dados de forma eficiente. Através da programação, algoritmos complexos podem ser implementados, dados podem ser visualizados e análises estatísticas podem ser realizadas. Ela fornece a flexibilidade e controle necessários para extrair insights significativos de vastos conjuntos de dados e embasar a tomada de decisões informadas em diversos domínios científicos e técnicos.

O estudo em questão envolve a implementação de técnicas de Aprendizado de Máquina como abordagem para investigar a previsão da resistência à compressão do concreto. Três técnicas, a saber, Regressão com Processo Gaussiano (LY; NGUYEN; PHAM, 2022), Regressão com

Floresta Aleatória (ZEINI *et al*, 2023) e Regressão com Perceptron de Múltiplas Camadas (PARK *et al*, 2021), são empregadas para desenvolver modelos de regressão capazes de prever propriedades e comportamentos na construção civil.

A regressão foi feita utilizando o algoritmo Perceptron de Múltiplas Camadas (MLP), explicado por Moreira (AIYER *et al*, 2014) como "uma rede neural com uma ou mais camadas ocultas com um número indeterminado de neurônios". O MLP é uma classe de redes neurais feedforward totalmente conectada, o que implica que todos os neurônios em cada camada estão conectados a todos os neurônios na camada subsequente, permitindo que o sinal de entrada se propague apenas em uma direção, em direção à saída. A Figura 4.3 exemplifica através de um esquema como a MLP funciona.

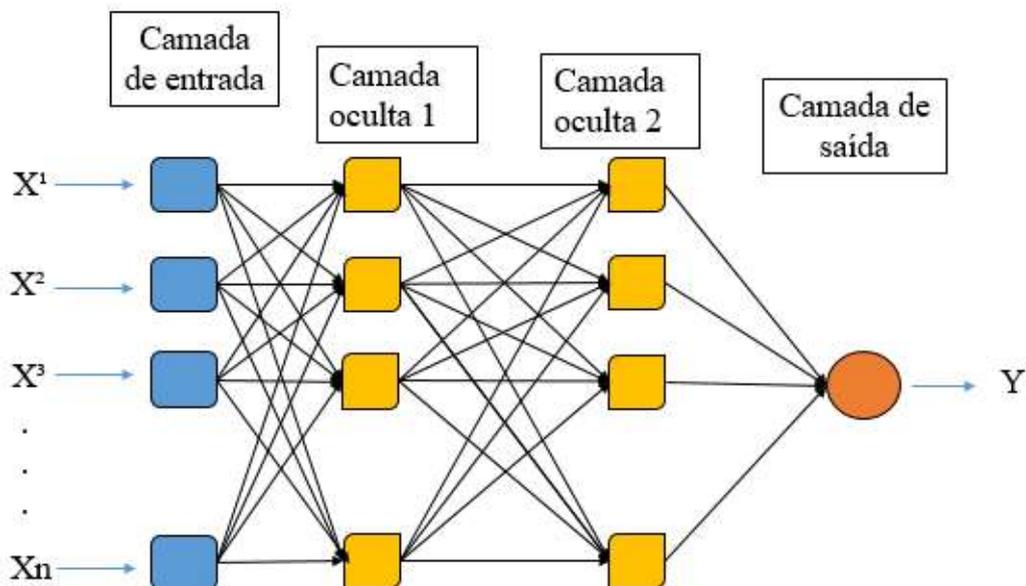


Figura 4.3- Representação de camadas ocultas em um modelo de redes neurais.

Fonte: Baseado em (PARK *et al*, 2021)

Essa técnica é comumente usada ao se obter um algoritmo de retropropagação com uma camada de saída neural. A análise envolve ajustar os hiperparâmetros usados para um melhor ajuste do modelo. Em resumo, aplica-se o Gradiente Descendente (GD), também conhecido como Método do Gradiente, juntamente com uma técnica eficaz para calcular gradientes automaticamente. Para cada instância de treinamento, são feitas previsões iniciais enquanto se preservam resultados intermediários, e o erro é medido comparando os valores previstos com

os valores observados. Em seguida, retropropagando pelas camadas de neurônios até atingir a camada de entrada, torna-se possível medir a contribuição de cada conexão para o erro. Por fim, com medidas do gradiente do erro em relação ao peso de cada conexão, aplicando o GD permite-se ajustar todos os pesos da rede e reduzir os erros. (PARK, 2021)

Através desses critérios pode-se determinar o desempenho do modelo. Os hiperparâmetros utilizados nos modelos da pesquisa estão apresentados na Tabela 4.4.

|                                    | <b>Caso 1</b> | <b>Caso 2</b> | <b>Caso 3</b> | <b>Caso 4</b> | <b>Caso 5</b> |
|------------------------------------|---------------|---------------|---------------|---------------|---------------|
| <b>solver</b>                      | lbfgs         | lbfgs         | Adam          | sgd           | lbfgs         |
| <b>alpha</b>                       | 0.01          | 0.01          | 0.1           | 0.001         | 0.01          |
| <b>n° de neurônios</b>             | 100           | 120.12        | 250.25        | 130.13        | 100.1         |
| <b>Função ativação</b>             | relu          | Relu          | Relu          | relu          | relu          |
| <b>Taxa de aprendizado inicial</b> | -             | 0.001         | 0.4           | -             | -             |

Tabela 4.4 - Hiperparâmetros utilizados pelo usuário

Fonte: Próprio Autor, 2023

### **4.3 ETAPA 3 - ANÁLISE ESTATÍSTICA DA TÉCNICA DE ACORDO COM OS CASOS APRESENTADOS**

Após a mineração de dados e do treinamento e teste, ocorre a análise dos resultados, onde os modelos são avaliados quanto à precisão e desempenho. Métricas adequadas são utilizadas para avaliar o desempenho, como erro quadrático médio raiz (RMSE), erro médio quadrático (MSE) e coeficiente de determinação ( $R^2$ ), além do Permutation Importance (PI) que ajuda a identificar as variáveis mais relevantes. A análise dos resultados também inclui a interpretação das relações e padrões descobertos pelo modelo, fornecendo insights sobre as características mais influentes na resistência à compressão do concreto. Por fim, na etapa de assimilação dos resultados, os insights obtidos são utilizados para informar decisões e ações relevantes, como a implementação do modelo em um sistema de suporte à decisão ou a aplicação dos resultados em projetos de construção, visando melhorar a qualidade e eficiência do concreto.

O  $R^2$  é usado para avaliar a correlação linear entre os valores observados e previstos dentro do intervalo. Ele mede a capacidade do modelo de explicar a variação no resultado, indicando o quão preditivo o modelo é. Seu valor pode variar de 0, indicando nenhuma variabilidade no

resultado (chance aleatória), a 1, indicando que o modelo explica todas as variabilidades (precisão total). (OH, 2022)

$$R^2 = 1 - \frac{\sum_{n=1}^n (\hat{y}_i - y_i)^2}{\sum_{n=1}^n (y_i - \bar{y})^2} \quad (2)$$

O erro quadrático médio (MSE) mede o erro médio ao quadrado das previsões do modelo, calculando a diferença entre o resultado experimental e os valores previstos e, em seguida, calculando a média. Por fim, o erro quadrático médio raiz (RMSE) mede a diferença entre os valores previstos e os valores reais ao quadrado, inseridos em uma raiz. Eles podem ser equiparados a um "desvio padrão dos erros".

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (4)$$

Essas métricas permitem a avaliação da qualidade do modelo com boa precisão, permitindo a comparação entre diferentes modelos e casos a serem analisados. Para os indicadores MSE e RMSE, um valor mais baixo é desejável, pois representa um modelo melhor, enquanto que para o  $R^2$ , um valor mais alto representa um ajuste mais próximo do ideal e uma previsão mais provável.

Outra métrica importante é a Permutation Importance (PI), ou Análise de Importância de Permutação. Ela é uma técnica utilizada na análise de modelos de Machine Learning para avaliar a importância relativa das variáveis de entrada (características) na previsão ou classificação de um determinado resultado. Essa técnica mede a influência de cada variável ao embaralhar aleatoriamente seus valores e observar como isso afeta o desempenho do modelo.

O procedimento da PI consiste em seguir os seguintes passos:

- Treinamento do modelo: Primeiro, o modelo é treinado utilizando os dados de treinamento disponíveis.
- Cálculo da métrica de desempenho: Em seguida, a métrica de desempenho, como a precisão ou o erro médio quadrático, é calculada utilizando os dados de teste ou validação.
- Permutação das variáveis: Uma variável de cada vez é permutada, ou seja, seus valores são aleatoriamente embaralhados entre as amostras do conjunto de dados de teste ou validação.
- Avaliação do desempenho permutado: O modelo é novamente utilizado para prever ou classificar os dados permutados e a métrica de desempenho é recalculada.
- Comparação de desempenhos: A diferença entre a métrica de desempenho original e a métrica de desempenho permutada é calculada para cada variável. Quanto maior a diferença, maior a importância da variável.

A PI fornece uma medida relativa da importância das variáveis, indicando quais têm maior influência nos resultados do modelo. Essa técnica é útil para entender quais características são mais relevantes para a predição ou classificação e pode auxiliar na seleção de características, na interpretação dos resultados e no ajuste do modelo.

## 5 RESULTADOS

Neste t3pico, apresenta-se e discute-se os resultados das tr3s etapas da pesquisa. Em primeiro lugar, descreve-se o desenvolvimento do conjunto de dados brasileiro com base nos disponibilizados no reposit3rio. Em seguida, treina-se um modelo para cada um dos cinco casos, que diferem de acordo com os dados utilizados para treinamento e teste. Por fim, 3 fornecida uma an3lise cr3tica detalhada dos dois melhores casos.

### 5.1 OBTENÇ3O DA BASE DE DADOS COMPATIBILIZADA

O conjunto de dados do UC Irvine Machine Learning Repository foi utilizado no estudo de Yeh (1998), que serve como refer3ncia para muitos estudos de previs3o de resist3ncia do concreto. Neste caso, Yeh utilizou 1080 inst3ncias para demonstrar a adaptabilidade de redes neurais artificiais na previs3o dessa propriedade em concreto de alto desempenho. Um conjunto de misturas de concreto foi produzido em laborat3rio e duas conclus3es principais foram tiradas: um modelo de resist3ncia baseado em redes neurais 3 mais preciso do que um modelo baseado em regress3o linear, e 3 conveniente e f3cil usar modelos de redes neurais artificiais para experimentos num3ricos para avaliar os efeitos de cada proporç3o de vari3vel na mistura de concreto. Este foi o conjunto de dados demonstrado nesta dissertaç3o para o Caso 2, tamb3m separando a amostra na proporç3o de 80%-20% para comparaç3o com o Caso 1.

A construç3o do conjunto de dados brasileiro começou ap3s a an3lise das conclus3es do treinamento usando apenas o conjunto de dados do reposit3rio. Os dados foram organizados em forma de tabela, em que cada coluna representa um componente. DATA\_BR2023 est3 dispon3vel em sua forma 3ntegra no Ap3ndice 1.

O conjunto de dados brasileiro e estrangeiros completo 3 exemplificado na Tabela 5.1, com os os valores m3ximos (Max), m3dios ( $\mu$ ), m3nimos (Min) e desvio padr3o ( $\sigma$ ). Atrav3s deles pode-se comparar e estimar as principais diferenç3as e semelhanç3as entre os traços nacionais e internacionais.

Primeiramente observa-se um consumo de cimento m3dio brasileiro de 310,22 kg/m<sup>3</sup> maior do que os 281,17 kg/m<sup>3</sup> da amostra internacional. Isso significa que o consumo de cimento no Brasil 3 maior do que na amostra internacional a resist3ncia m3xima 3 compress3o de 84,90 MPa tamb3m 3 maior do que a de 82,60 MPa da amostra internacional.

Por outro lado, a quantidade média de escória de 73,90 kg/m<sup>3</sup> em DATA\_YEH1998 é bem superior à observada em DATA\_BR2023 de 20,31 kg/m<sup>3</sup>. A quantidade média de pozolana segue a mesma tendência de 54,19 kg/m<sup>3</sup> em DATA\_YEH1998 e 14,19 kg/m<sup>3</sup>. Isso pode ser sustentado pelo fato do banco de dados brasileiro utilizar esses SCM's incorporados no cimento e essas quantificações foram calculadas de acordo no item 4.1, enquanto que em DATA\_YEH1998 foram diretamente incorporados no concreto.

Adicionalmente, cabe ressaltar que os concretos brasileiros utilizam mais água (197,39 kg/m<sup>3</sup>) do que os concretos estrangeiros (181,57 kg/m<sup>3</sup>) uma diminuição de 8,01% e conseqüentemente consomem menos aditivo (1,97 kg/m<sup>3</sup>) do que os estrangeiros (6,20 kg/m<sup>3</sup>), menos de 68,22%. O consumo de agregados médio, tanto miúdos quanto graúdos, foi próxima entre as duas bases de dados.

As maiores variações entre DATA\_BR2023 e DATA\_YEH1998 foram referentes as idades em que foram realizados os ensaios após a cura. Na base de dados brasileira foram consideradas somente as idades aos 7 e 28 dias enquanto na base de dados estrangeira foram coletados dados de 1 a 365 dias. A resistência à compressão média foi de 32,13 MPa (DATA\_BR2023) e 35,82 MPa (DATA\_YEH1998).

| Inputs  | BR2023  |         |        |        | YEH98   |        |        |        |
|---|---------|---------|--------|--------|---------|--------|--------|--------|
|   | Máx     | μ       | Min    | σ      | Máx     | μ      | Min    | σ      |
| <b>Cimento (kg/m<sup>3</sup>)</b>               | 526.50  | 310.22  | 121.50 | 80.01  | 540.00  | 281.17 | 102.00 | 104.51 |
| <b>Escória de Alto Forno (kg/m<sup>3</sup>)</b> | 250.00  | 20.31   | 0.00   | 41.43  | 359.40  | 73.90  | 0.00   | 86.28  |
| <b>Pozolana (kg/m<sup>3</sup>)</b>              | 151.31  | 14.75   | 0.00   | 3.49   | 200.10  | 54.19  | 0.00   | 64.00  |
| <b>Água (kg/m<sup>3</sup>)</b>                  | 361.10  | 197.39  | 116.33 | 27.82  | 247.00  | 181.57 | 121.75 | 21.36  |
| <b>Aditivo (kg/m<sup>3</sup>)</b>               | 12.21   | 1.97    | 0.00   | 2.42   | 32.20   | 6.20   | 0.00   | 5.97   |
| <b>Agregado graúdo (kg/m<sup>3</sup>)</b>       | 1573.00 | 1016.83 | 463.13 | 138.16 | 1145.00 | 972.92 | 801.00 | 77.75  |
| <b>Agregado miúdo (kg/m<sup>3</sup>)</b>        | 1662.29 | 786.94  | 127.00 | 154.11 | 992.60  | 773.58 | 594.00 | 80.18  |

|                                       |       |       |      |       |        |       |      |       |
|---------------------------------------|-------|-------|------|-------|--------|-------|------|-------|
| <b>Idade (dias)</b>                   | 28.00 | 19.30 | 7.00 | 10.36 | 365.00 | 45.66 | 1.00 | 63.17 |
| <b>Resistência à compressão (MPa)</b> | 84.90 | 32.13 | 7.00 | 12.27 | 82.60  | 35.82 | 2.33 | 16.71 |

Tabela 5.1- Dados estatísticos das duas bases de dados analisadas

Fonte: Próprio Autor, 2023

### 5.1.1 DATA\_BR2023

O banco de dados brasileiro, após compatibilizado, foi submetido à uma análise de dados de entrada através de um estudo preliminar dos parâmetros, sendo possível melhor visualizar e entender quais dados tem mais relações com outros, além da observação de medidas centrais, de dispersão e da distribuição de cada variável.

Para isso utiliza-se a Matriz de Correlação entre as variáveis em estudo. O esquema de cores das Figuras 5.1 e 5.2 indicam o nível de correlação entre as variáveis analisadas, quanto mais próximas do marrom, maior será sua correlação direta e quanto mais escura a tonalidade do azul maior será sua correlação inversa.

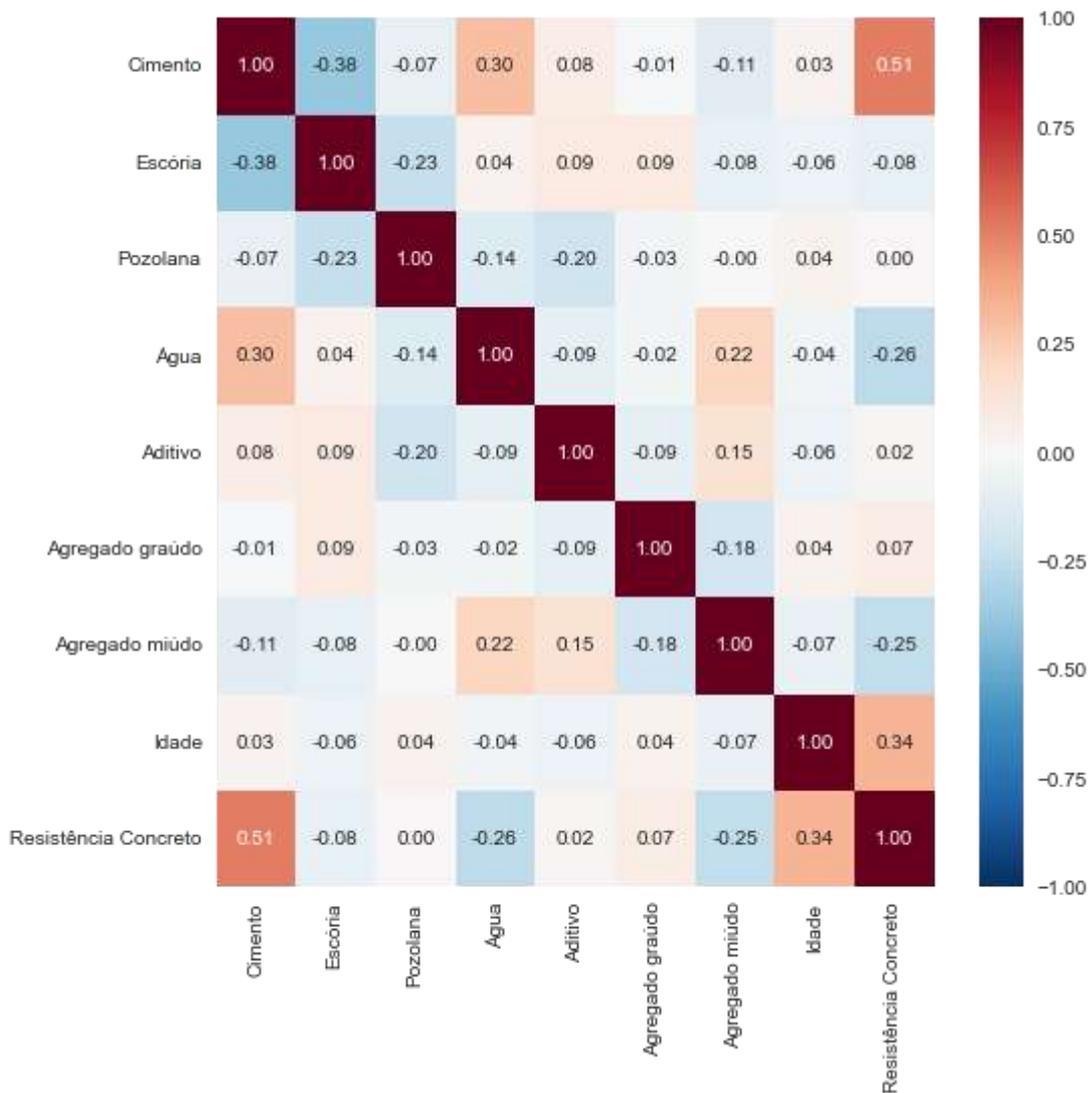


Figura 5.1 - Correlação de Pearson em DATA\_BR23

Fonte: Próprio Autor, 2023

Analisando a Figura 5.1 observa-se que a maior parte das variáveis apresenta valor de correlação abaixo de 0,5. Em relação à resistência à compressão os parâmetros consumo de cimento e idade são aqueles com relação maior que 0,33 (em termos absolutos). Essa correlação entre os parâmetros pode ser explicada pela característica que o cimento é o principal ligante do concreto, que após hidratado ele vai ser o responsável central no ganho de resistência ao longo do tempo. A idade de cura, também se relaciona diretamente com a resistência à compressão pois indica o estágio de hidratação do cimento, neste caso aos 7 e 28 dias.

Apresentando uma correlação inversa nessa base dados aparece a água e o agregado miúdo. A relação entre água e resistência à compressão de acordo com a Lei de Abrams, já demonstrava matematicamente o comportamento de que quanto maior a quantidade de água menor a

resistência à compressão. O uso de alguns aditivos pode mitigar esse efeito, mas para esta base de dados em específico a correlação existente entre aditivo e resistência à compressão foi somente de 0,02. Isso pode ser explicado pois muitos traços coletados não apresentava aditivo, fazendo com que analisando todo o conjunto seu uso não foi relevante. A correlação Pozolana e resistência à compressão foi igual a zero. Isso pode ser explicado pelo fato de poucas amostras apresentarem pozolana ao ter sido feito o cálculo da estimativa desse quantitativo referente ao cimento utilizada. Dessa forma optou-se pela retirada da Pozolana dessa base de dados.

Os resultados dos histogramas, visto que os dados são quantitativos, podem ser expressos para DATA\_BR2023 na Figura 5.2 para cada variável.

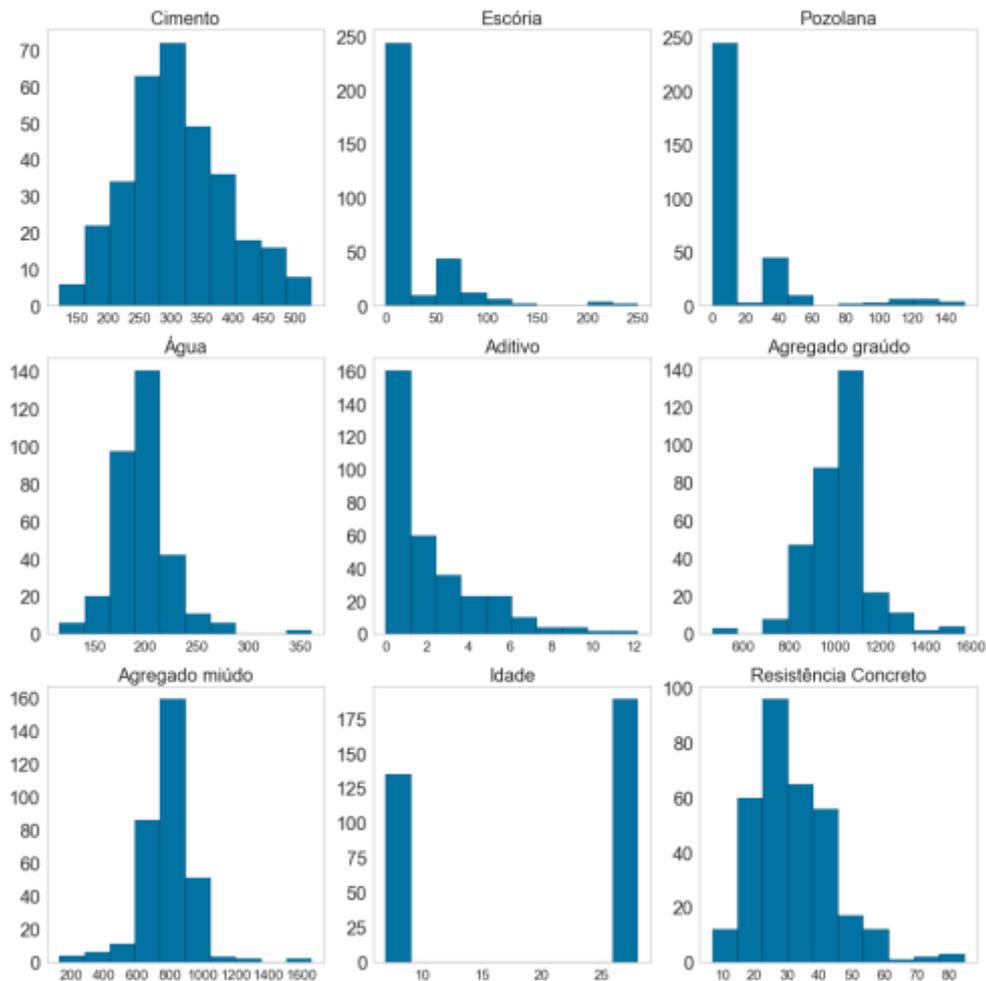


Figura 5.2- Histogramas com DATA\_BR23

Fonte: Próprio Autor, 2023

Através dos histogramas dos dados de entrada, pode-se observar uma ampla variedade de dados, dos 8 inputs, além do parâmetro de output resistência à compressão. O histograma é um resultado gráfico de distribuição de dados para análise de variáveis em que o eixo horizontal representa os valores da variável e o eixo vertical a frequência ou contagem de ocorrência no banco de dados.

Para a variável “Cimento”, em DATA\_BR23, encontra-se uma maior frequência do consumo de cimento em média de 300 kg/m<sup>3</sup>. Essa proporção pode ser aplicada para concretos de resistência média, como os utilizados em diversas aplicações de construção civil. Geralmente, concretos de resistência média têm uma resistência à compressão que varia de cerca de 20 MPa a 40 MPa. Essa é uma faixa comum para muitas estruturas de edifícios, lajes, fundações, pisos, calçadas e outros elementos de construção que não exigem altas cargas ou esforços excepcionais (BARROS, 2019).

As variáveis “Escória de Alto Forno” e “Pozolana” apresentaram distribuição bem semelhante provavelmente devido ao cálculo aproximado de quantificação desses compostos e à utilização de uma quantidade aproximada de concretos com cimentos que possuem. Ambas com quantidade inferior da 20 kg/m<sup>3</sup>. Como a maioria dos cimentos utilizados na fabricação dos concretos são CP II-F e CP II-E, ou seja, compostos por fíler e escória de alto forno, simultaneamente, esses compostos tendem a aparecer com uma frequência maior. O fíler calcário não foi considerado como dado de entrada na pesquisa pois não estava presente na base de dados estrangeira, apesar dos cimentos brasileiros possuírem um determinado teor de fíler incorporado.

Em relação à quantidade média de água de amassamento utilizada nos traços analisados esteve entre 200 e 300 kg/m<sup>3</sup>. Como cada traço foi retirado de um artigo com metodologias distintas não se pode inferir a razão pela qual essa faixa foi predominante. Os principais fatores que influenciarão a quantidade de água é a quantidade de aditivo e os finos presentes na mistura. A quantidade de agregados miúdos fica na faixa de 700 a 800 kg/m<sup>3</sup> enquanto que para os grãos a faixa fica entre 1000 e 1100 kg/m<sup>3</sup>. Nesse banco de dados somente foram coletadas amostras após 7 e 28 dias de cura.

### 5.1.2 DATA\_YEH1998

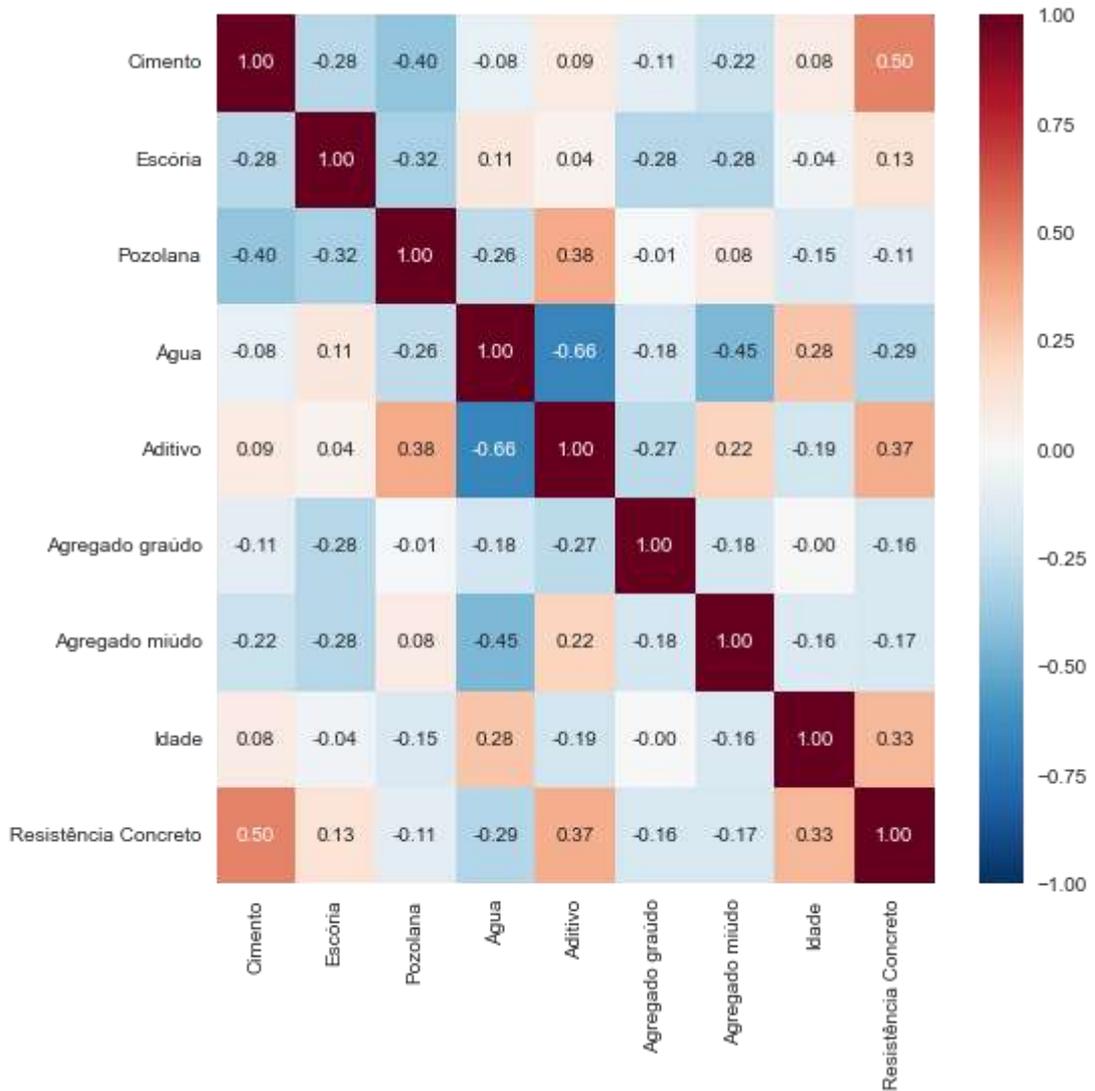


Figura 5.3- Correlação de Pearson em DATA\_YEH98

Fonte: Próprio Autor, 2023

Ao analisar os dois bancos de dados, é importante avaliar a correlação de Pearson entre cada variável, como mostrado na Figura 5.1 e 5.3, para auxiliar na seleção de características. Em relação à variável alvo, o Cimento foi a entrada com a maior correlação de Pearson, com valor absoluto próximo de 1, com valores de 0,5 para YEH98 e 0,51 para BR2023, indicando uma forte relação com a resistência à compressão e justificando sua seleção. O Cimento é o componente principal do concreto, com propriedades de ligação diretamente relacionadas às características do seu estado endurecido.

Com relação à correlação entre as entradas, a água e o aditivo se destacam com uma correlação de -0,66 em YEH98. Em nenhum dos bancos de dados houve correlação maior que 0,9 entre as entradas, o que é um aspecto positivo, pois, se isso ocorresse, poderia haver multicolinearidade, interferindo potencialmente no modelo.

O aditivo em DATA\_YEH98 apresentou maior influência que na base de dados brasileira com índice igual a 0,37. Isso é explicado pelo uso sistemático nos traços desenvolvidos na elaboração dessa base de dados que foi preponderantemente superplastificantes que altera a reologia do concreto em estado fresco e influencia diretamente no ganho futuro de resistência à compressão.

Também pode-se destacar pelas matrizes de correlação que, em ambos os bancos de dados, a entrada Pozolana apresenta a menor correlação com a resistência à compressão. Por esse motivo, decidiu-se não selecionar essa variável, sendo a única do conjunto de dados que não foi utilizada nos modelos.

Isso pode ser justificado principalmente pelo fato de que, ao estimar as quantidades de Pozolana e Escória de Alto-Forno em BR2023 com base no consumo médio de cimento prescrito pelas normas brasileiras, o cálculo não foi suficiente para refletir a quantidade real de material nas amostras de cimento coletadas da literatura, ao contrário de YEH98, onde as entradas foram relevantes. Considerando o conhecimento no campo dos materiais, sabe-se que esses materiais cimentícios complementares influenciam diretamente a resistência à compressão. Assim, todas as outras entradas, exceto a Pozolana, foram usadas nos modelos.

Por se tratar de traços obtidos através de artigos científicos, houve um controle laboratorial rígido que pode ser distinto de alguns outros traços que foram obtidos no canteiro de obras. Isso pode explicar a existência de *outliers* e valores fora do padrão observado. Assim, como observado na base de dados brasileira, os dados de entrada da base de dados internacional podem ser analisados por histogramas como na Figura 5.4.

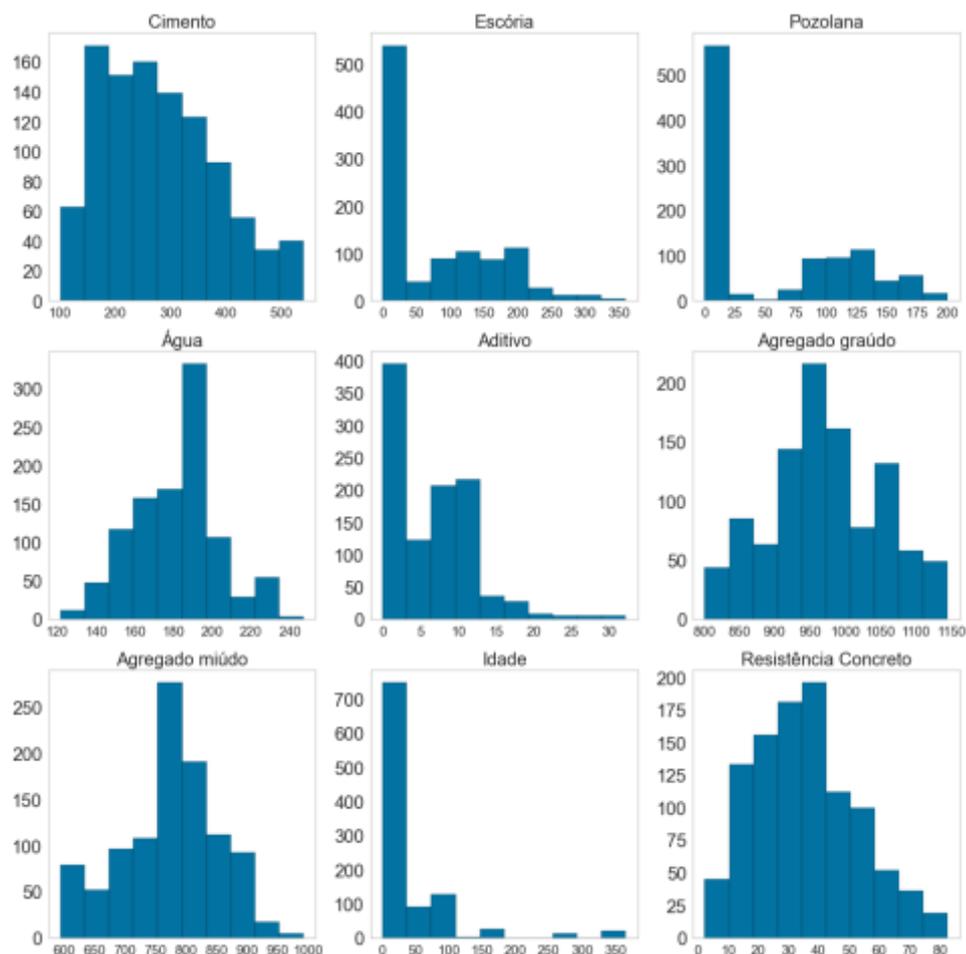


Figura 5.4 - Histogramas dos inputs em DATA\_YEH98

Fonte: (Próprio Autor, 2023)

No conjunto de dados DATA\_YEH98, considerando o banco de dados de referência, observa-se uma maior variedade em termos dos dias nos quais o espécime foi rompido para o teste, com a maioria concentrada dentro de no máximo 50 dias. Mesmo que pequenas, em relação à esse input é possível observar amostras de até 350 dias, próximos à um ano.

Em relação ao consumo de água, caso fosse utilizado o input “Relação a/c” em seu lugar seria possível visualizar o mesmo comportamento visto que as proporções são as mesmas. As resistências alcançadas chegam a aproximadamente 200 MPa, são duas vezes maiores do que os valores mais altos analisados no conjunto de dados DATA\_BR2023.

## 5.2 TREINAMENTO DA TÉCNICA DE ML USANDO ANN

Abaixo está a Tabela 5.2 com os valores máximos (Max), médios ( $\mu$ ), mínimos (Min) e desvio padrão ( $\sigma$ ) das resistências previstas obtidas para cada caso:

| Resistência Prevista (MPa) |          |             |       |
|----------------------------|----------|-------------|-------|
|                            |          | Treinamento | Teste |
| Caso 1 TR_TE.BR            | Máx      | 74.55       | 70.62 |
|                            | $\mu$    | 31.95       | 31.83 |
|                            | Min      | 6.2         | 5.13  |
|                            | $\sigma$ | 10.99       | 11.50 |
| Caso 2 TR_TE.YEH           | Máx      | 79.07       | 81.43 |
|                            | $\mu$    | 35.73       | 36.21 |
|                            | Min      | 6.44        | 4.43  |
|                            | $\sigma$ | 16.78       | 16.62 |
| Caso 3 TR.YEH_TE.BR        | Máx      | 75.19       | 59.47 |
|                            | $\mu$    | 38.06       | 28    |
|                            | Min      | 8.92        | 2.71  |
|                            | $\sigma$ | 15.97       | 9.43  |
| Caso 4 TR.BR_TE.YEH        | Máx      | 66.83       | 67.37 |
|                            | $\mu$    | 30.85       | 33.36 |
|                            | Min      | 13          | 13.53 |
|                            | $\sigma$ | 9.237       | 11.63 |
| Caso 5 TR_TE.ALL           | Máx      | 78.7        | 83.25 |
|                            | $\mu$    | 34.83       | 35.08 |
|                            | Min      | 9.11        | 2.27  |
|                            | $\sigma$ | 11.69       | 16.06 |

Tabela 5.2 - Resistência Prevista (MPa) para todos os casos: (Max), médios ( $\mu$ ), mínimos (Min) e desvio padrão ( $\sigma$ )

Fonte: Próprio Autor, 2023

### 5.2.1 Comparação entre Casos

Em primeiro lugar, considera-se que como em todos os 5 casos foi utilizada a mesmo tipo de ANN para treinamento e teste (MLP), deve-se considerar o Caso 2 como referência aos demais casos, uma vez que possui tamanho e representatividade consideráveis da DATA\_YEH1998 com 1080 instâncias, notavelmente maior que as 324 instâncias de DATA\_BR2023.

Comparado ao Caso 2, o Caso 1 (TR\_TE.BR) apresenta uma baixa variação em relação à média entre as amostras de treinamento e teste, com um desvio padrão de 10,99 e 11,50, respectivamente. Isso pode ser explicado pelo fato de que, no caso 2, o banco de dados utilizou

dados de vários países, enquanto o brasileiro utilizou apenas dados nacionais. Isso acontece com os casos 3, 4 e 5 que também apresentam desvio padrão no teste e treinamento menores que aqueles observados no Caso 2 de 16,78 MPa e 16,68 MPa, respectivamente, justificados pela mesma razão.

No entanto, nos Casos 3 e 4, podem ser observadas diferenças mais significativas entre o mesmo banco de dados usado para treinamento e teste. Nestes dois casos, conjuntos de dados diferentes foram trocados entre treinamento e teste. A diferença entre os valores médios do conjunto de dados DATA\_YEH1998 foi de 12,34%, enquanto para o DATA\_BR2023 foi de 9,24%. Neste caso, o uso de diferentes bancos de dados nos conjuntos de treinamento e teste pode ter sido responsável por uma maior variação.

Observando cada caso isoladamente é possível notar que nos Casos 1 e 2, como foram utilizadas a mesma base de dados para treinamento e teste em cada caso, os valores máximos, mínimos, média e desvio foram bem próximos. No Caso 5, porém apesar de valores de máximo, mínimo e média próximos, a diferença de desvio de treinamento (11,69 MPa) e de teste (16,06 MPa) são maiores, provavelmente devido a variação dos valores ao unir-se duas bases de dados.

Assim, em todos os casos apresentados, os valores médios previstos foram superiores a 25 MPa e inferiores a 40 MPa, indicando que os concretos analisados pertencem à Classe I, de acordo com a NBR 8953 (ABNT, 2015) que compreende concretos com resistência entre 25 MPa e 50 MPa. O Caso 5 apresentou a maior variância, com uma resistência prevista máxima de 83,25 MPa e  $\sigma=16,06$  nos resultados de teste.

### 5.3 ANÁLISE ESTATÍSTICA E TÉCNICA DE ACORDO COM OS CASOS APRESENTADOS

A Tabela 5.3 resume os resultados dos parâmetros estatísticos para cada caso.

| Parâmetros Estatísticos |                |             |       |
|-------------------------|----------------|-------------|-------|
|                         |                | Treinamento | Teste |
| Caso 1 TR_TE.BR         | R <sup>2</sup> | 0,9         | 0,77  |
|                         | MSE            | 14,12       | 40,63 |
|                         | RMSE           | 3,76        | 6,37  |
| Caso 2 TR_TE.YEH        | R <sup>2</sup> | 0,99        | 0,94  |
|                         | MSE            | 3,35        | 17,67 |

|                            |                      |       |       |
|----------------------------|----------------------|-------|-------|
|                            | <b>RMSE</b>          | 1,83  | 4,2   |
| <b>Caso 3 TR.YEH_TE.BR</b> | <b>R<sup>2</sup></b> | 0,8   | 0,93  |
|                            | <b>MSE</b>           | 56,2  | 86,33 |
|                            | <b>RMSE</b>          | 7,5   | 9,29  |
| <b>Caso 4 TR.BR_TE.YEH</b> | <b>R<sup>2</sup></b> | 0,6   | 0,67  |
|                            | <b>MSE</b>           | 60,64 | 77,56 |
|                            | <b>RMSE</b>          | 7,78  | 8,81  |
| <b>Caso 5 TR_TE.ALL</b>    | <b>R<sup>2</sup></b> | 0,97  | 0,86  |
|                            | <b>MSE</b>           | 6,88  | 36,11 |
|                            | <b>RMSE</b>          | 2,62  | 6,01  |

Tabela 5.3- Parâmetros Estatísticos

Fonte: Próprio Autor, 2023

### 5.3.1 Caso 1 TR\_TE.BR

Com um  $R^2$  de 0,9 no conjunto de treinamento e 0,77 no conjunto de teste, o Caso 1 indica uma boa capacidade de ajuste do modelo aos dados de treinamento, mas uma menor capacidade de generalização para novos dados no conjunto de teste. A capacidade de ajuste do modelo de redes neurais se refere à habilidade de aprender padrões complexos dos dados de treinamento.

Quanto maior a capacidade de ajuste, mais complexas podem ser as funções que o modelo aprende. Já a capacidade de generalização é a capacidade do modelo de aplicar o que aprendeu em dados não vistos durante o treinamento, ou seja, de fazer previsões precisas em novas situações. Encontrar o equilíbrio entre a capacidade de ajuste e a generalização é fundamental para um modelo eficaz e com bom desempenho. (YOUNG, 2019).

O valor de MSE e RMSE no conjunto de teste é maior do que no conjunto de treinamento, o que pode sugerir uma tendência de overfitting, onde o modelo pode estar se ajustando demais aos dados de treinamento, capturando ruídos e detalhes irrelevantes e não generalizando tão bem para dados não vistos.

### 5.3.2 Caso 2 TR\_TE.YEH

O Caso 2 apresenta um alto  $R^2$  tanto no conjunto de treinamento (0,99) quanto no conjunto de teste (0,94). Além disso, os valores de MSE e RMSE no conjunto de teste são relativamente baixos. Esses resultados indicam que o modelo tem um excelente desempenho tanto na fase de treinamento quanto na fase de teste, demonstrando boa capacidade de generalização.

### 5.3.3 Caso 3 TR.YEH\_TE.BR

O Caso 3 apresenta um  $R^2$  de 0,8 no conjunto de treinamento e 0,93 no conjunto de teste, indicando uma boa capacidade de ajuste e generalização do modelo. No entanto, os valores de MSE e RMSE no conjunto de teste são relativamente altos em comparação com os outros casos, sugerindo que o modelo pode não estar tão preciso em suas previsões em relação aos dados de teste.

### 5.3.4 Caso 4 TR.BR\_TE.YEH

O Caso 4 tem um  $R^2$  relativamente baixo, tanto no conjunto de treinamento (0,6) quanto no conjunto de teste (0,67), sugerindo um ajuste moderado e capacidade de generalização. Os valores de MSE e RMSE no conjunto de teste também são mais elevados em comparação com outros casos, o que indica um desempenho não tão preciso no conjunto de teste.

### 5.3.5 Caso 5 TR\_TE.ALL

O Caso 5 apresenta um alto  $R^2$  no conjunto de treinamento (0,97) e um valor razoavelmente alto no conjunto de teste (0,86). Isso pode ser justificado porque, nesse caso, houve a união das duas bases de dados em uma só, aumentando consequentemente o número de instâncias. Os valores de MSE e RMSE no conjunto de teste são mais altos em relação aos do conjunto de treinamento, indicando uma boa capacidade de ajuste, mas uma capacidade de generalização relativamente menor.

### 5.3.6 Resumo e Comparação entre Casos

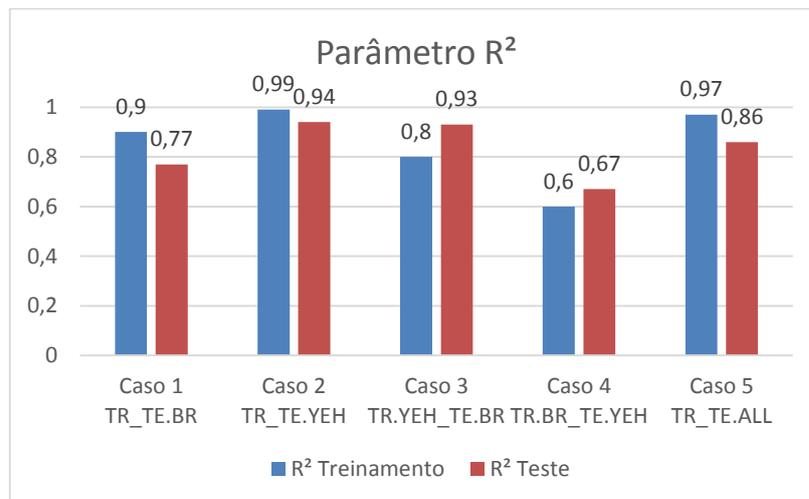


Figura 5.5 Parâmetro  $R^2$  para todos os casos

Fonte: Próprio Autor, 2023

A Figura 5.5 compara os valores de  $R^2$  para cada caso. É possível observar que os melhores resultados para treinamento foram, em ordem crescente: Caso 4, Caso 3, Caso 1, Caso 5 e Caso 2. Para teste, também em ordem crescente: Caso 3, Caso 4, Caso 1, Caso 5 e Caso 2.

Os Casos 1, 2 e 5 foram satisfatórios para a modelagem, pois apresentaram um ajuste e comportamento mais linear em relação ao  $R^2$ . Por outro lado, os Casos 3 e 4 variaram de uma maneira que tornou o ajuste mais difícil. Assim, usar dados brasileiros para treinar um modelo e testá-lo com dados do repositório não é adequado, e vice-versa.

Em geral, é esperado que o valor de  $R^2$  para o conjunto de treinamento seja maior do que o  $R^2$  para o conjunto de teste, o que não ocorre nos Casos 3 e 4. Isso geralmente ocorre porque o modelo foi ajustado especificamente aos dados de treinamento durante o processo de aprendizagem, o que pode resultar em um bom ajuste para esses dados como nos Casos 1, 2 e 5. No entanto, quando o modelo é avaliado em dados não vistos durante o treinamento (conjunto de teste), pode ocorrer uma queda no desempenho, pois o modelo pode não generalizar tão bem para novos dados como nos Casos 3 e 4.

Nesse sentido, usar uma ANN é uma escolha específica e justificada de acordo com os autores (YEH, 1998) (YEH, 1999) (GUPTA, 2013) (YEH, 2006) e depende do conjunto de dados utilizado. No estudo de Yeh (1998), utilizando quatro modelos distintos com inputs variáveis, foram obtidos valores de RMSE entre 2 MPa e 4.5 MPa com as Redes Neurais de Neurônios Complementares tanto para teste quanto para treinamento. Esse parâmetro avalia a precisão da rede, e assim nos Casos 3 e 4 não há muita precisão, com este parâmetro maior que 7 MPa, o máximo permitido por normas brasileiras de acordo com as condições de preparo. A Figura 5.6 ajuda na melhor visualização dos parâmetros RMSE de todos os casos em conjunto.

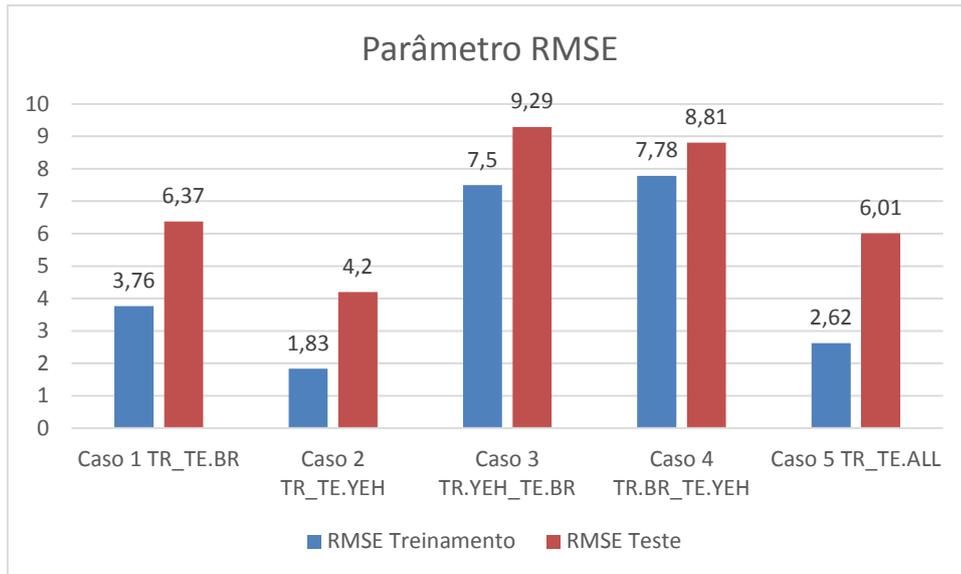


Figura 5.6 Parâmetro RMSE em todos os casos.

Fonte: Próprio Autor, 2023

Em outro estudo, Yeh (2006) utilizou uma ANN no mesmo caso para prever a resistência de concretos de alta e baixa resistência com base na variação da cinza volante, obtendo no melhor caso um RMSE de 3.96 MPa ( $R^2=0.890$ ) e 8.82 MPa ( $R^2=0.791$ ) para dados de treinamento e teste, respectivamente. Portanto, apenas no teste do Caso 3, foi obtido um RMSE de 9 MPa ( $R^2=0.43$ ), reforçando mais uma vez que o modelo não teve bom desempenho. O RMSE e o MSE dependem da unidade utilizada da variável (neste caso MPa) e podem refletir em valores mais altos uma vez que elevam o erro existente ao quadrado.

Em resumo, o Caso 2 (TR\_TE.YEH) parece ser o melhor desempenho geral, com um alto  $R^2$  e baixos valores de MSE e RMSE no conjunto de teste, o que sugere que ele tem a melhor capacidade de ajuste e generalização para novos dados. Já o Caso 4 (TR.BR\_TE.YEH) demonstra ser o pior desempenho geral, com  $R^2$  relativamente baixo e valores mais altos de MSE e RMSE no conjunto de teste, indicando uma capacidade de previsão inferior em relação aos outros casos. Os valores do parâmetro MSE podem ser observados na Figura 5.7.

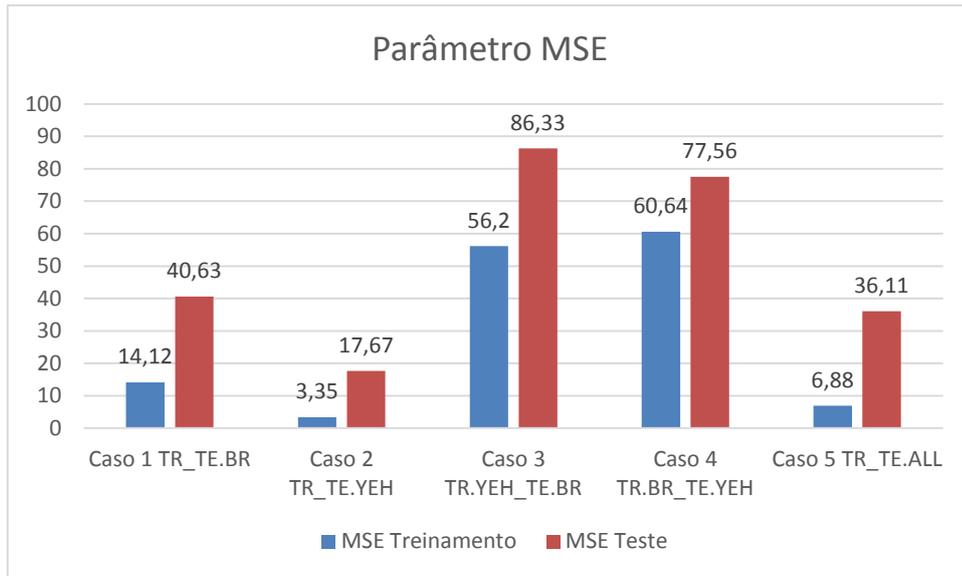


Figura 5.7 Parâmetro MSE pra todos os casos.

Fonte: Próprio Autor, 2023

Cabe destacar ainda que os Casos 3 e 4 apresentaram MSE entre 75 e 90 MPa. Paudel *et al.* (2023) obteve um parâmetro de 88,23 MPa, nesse mesmo intervalo, e afirma que erros representados por MSE superiores a 75 MPa podem indicar modelagens que não conseguiram prever bem a resistência à compressão ao serem testados.

Os resultados dos gráficos que relacionam a resistência observada e a resistência prevista em cada um dos casos são mostrados na Figura 5.8.

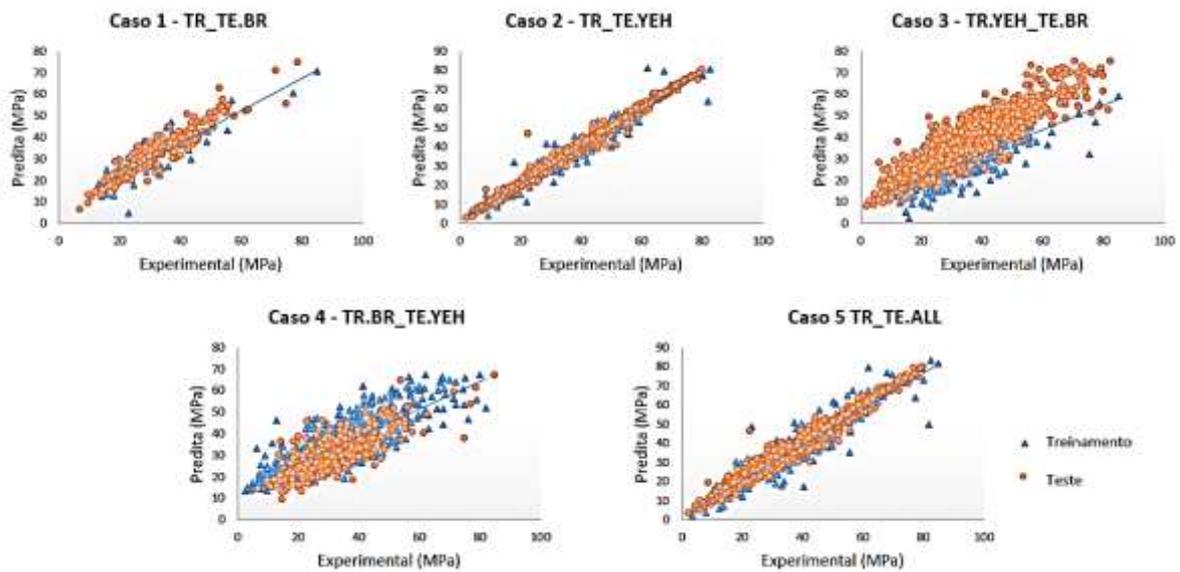


Figura 5.8 - Gráficos de tendências dos 5 casos

Fonte: Próprio Autor, 2023

O gráfico da linha de igualdade representa a situação ideal em que os valores previstos coincidem perfeitamente com os valores observados. A proximidade dos valores previstos com a linha de igualdade indica uma concordância com os valores reais de resistência do concreto, especialmente no Caso 2, que utiliza apenas o conjunto de dados DATA\_YEH1998, e no Caso 5, que utiliza todos os conjuntos de dados.

Os gráficos na Figura 5.8 demonstram que o Caso 2 é o que apresenta o melhor ajuste em comparação com os demais, portanto, a análise do modelo conclui que é o caso ideal. No entanto, esse caso considera apenas o conjunto de dados Yeh (1998). O Caso 5 apresenta a segunda melhor performance e utiliza amostras dos conjuntos de dados DATA\_BR2023 e DATA\_YEH98 como treinamento e teste, apresentando um valor de RMSE de 2,62 no treinamento e 6,01 no teste.

Por fim, é importante realizar a Análise de Importância (PI) para avaliar quais as variáveis de entrada mais relevantes nos melhores casos.

### 5.3.7 Análise de Importância (PI)

Finalmente, a Análise de Importância foi realizada utilizando os Casos 2 e 5, pois apresentaram os melhores resultados gerais. Foram realizadas 500 permutações para cada variável de entrada individualmente, e essa ferramenta mede o quanto o RMSE diminui, permitindo entender quais variáveis foram mais relevantes para os modelos. Isso é mostrado na Tabela 5.4 e na Figura 5.9.

No Caso 2, a ordem de relevância, em ordem crescente, foi: Idade, Cimento, Água, Agregado Miúdo, Escória de Alto-Forno, Agregado Graúdo e Aditivo. No Caso 5, Idade e Cimento permaneceram como as duas variáveis mais relevantes, mas em uma ordem diferente, como ilustrado na Figura 5.9, na seguinte sequência: Cimento, Idade, Escória de Alto-Forno, Água, Aditivo, Agregado Miúdo e Agregado Graúdo.

| Input                        | Permutation Importance (Análise de Importância) |          |               |          |
|------------------------------|---|----------|---------------|----------|
|                              | Caso 2  |          | Caso 5        |          |
|                              | RMSE ( $\mu$ )                                  | $\sigma$ | RMSE( $\mu$ ) | $\sigma$ |
| <b>Cimento</b>               | 0,136   | 0,01     | 0,167         | 0,009    |
| <b>Idade</b>                 | 0,144   | 0,008    | 0,105         | 0,007    |
| <b>Escória de alto forno</b> | 0,082   | 0,007    | 0,086         | 0,011    |
| <b>Água</b>                  | 0,095   | 0,006    | 0,082         | 0,007    |
| <b>Aditivo</b>               | 0,056   | 0,006    | 0,068         | 0,007    |
| <b>Agregado miúdo</b>        | 0,086   | 0,008    | 0,06          | 0,009    |
| <b>Agregado graúdo</b>       | 0,069   | 0,006    | 0,047         | 0,007    |

Tabela 5.4 - Análise de Importância

Fonte: Próprio Autor, 2023

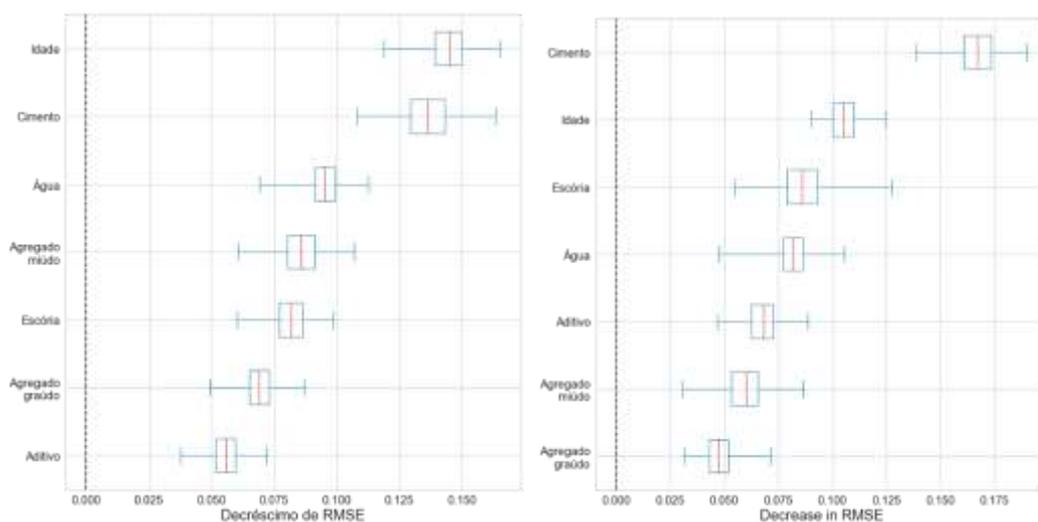


Figura 5.9 - Fator de Importância no Caso 2 (Esquerda) e Caso 5 (direita)

Fonte: Próprio Autor, 2023

No Caso 2, as variáveis mais importantes para a previsão do RMSE são, em ordem de maior importância para menor: Idade, Cimento, Água, Agregado miúdo, Escória de alto forno, Agregado graúdo e aditivo. Isso significa que a variável "Idade" tem a maior contribuição para

o desempenho do modelo em relação ao RMSE no Caso 2. A variável "Cimento" também tem uma importância significativa, mas um pouco menor que a "Idade". As outras variáveis têm importância relativamente menor.

Como no Caso 2, utilizou-se a mesma base de dados DATA\_YEH1998 para treinamento e teste conclui-se que o dado de entrada "Idade" foi mais relevante principalmente devido a amplitude de idades após a cura (de 1 a 365 dias) utilizadas para se obter a resistência à compressão do concreto.

A idade é um fator crucial que influencia significativamente a resistência à compressão dos concretos. Durante o processo de hidratação do cimento, o concreto passa por um período de endurecimento contínuo, à medida que a reação química progride ao longo do tempo. Conseqüentemente, a resistência do concreto aumenta à medida que ele envelhece. É importante considerar a idade do concreto ao avaliar sua capacidade estrutural e ao planejar a aplicação de cargas. Em geral, quanto mais tempo o concreto tem para hidratar e ganhar resistência, mais adequado ele será para suportar as exigências mecânicas das estruturas, garantindo sua durabilidade e desempenho ao longo do tempo. (CHAABENE et al, 2020)

No Caso 5, as variáveis mais importantes para a previsão do RMSE são, em ordem de maior importância para menor: Cimento, Idade, Escória de alto forno, Água, Aditivo, Agregado miúdo e Agregado graúdo. Neste caso, o consumo de cimento é a variável mais relevante. As outras variáveis têm importância relativamente menor em relação ao RMSE no Caso 5.

O consumo adequado de cimento é crucial para garantir a resistência à compressão dos concretos, pois é o principal componente responsável pela formação do gel de silicato de cálcio hidratado (CSH) durante o processo de hidratação. O CSH é o agente aglutinante que une os grãos de cimento e agregados, proporcionando a coesão necessária para suportar cargas de compressão. Uma dosagem adequada de cimento assegura a formação de uma matriz sólida e resistente, essencial para a qualidade e desempenho das estruturas de concreto.

Em resumo, a análise de importância de permutação nos Casos 2 e 5 indica que as variáveis "Idade" e "Cimento" têm uma influência significativa no desempenho do modelo em relação ao RMSE, sendo as variáveis mais importantes. As outras variáveis também contribuem para o desempenho do modelo, mas com importância relativa menor.

## 6 CONSIDERAÇÕES FINAIS

### 6.1 CONCLUSÕES

Este estudo investiga prevê a resistência à compressão através de uma análise comparativa de duas bases de dados correspondentes usando o algoritmo MultiLayer Perceptron (MLP). Um conjunto de dados contendo 324 experimentos em concretos brasileiros foi usado para gerar os conjuntos de dados de treinamento e teste para o desenvolvimento do algoritmo MLP. Os componentes considerados do concreto (entradas) foram oito: Cimento ( $\text{kg/m}^3$ ), Escória de Alto Forno ( $\text{kg/m}^3$ ), Água ( $\text{kg/m}^3$ ), Agregado Graúdo ( $\text{kg/m}^3$ ), Aditivo ( $\text{kg/m}^3$ ), Agregado Miúdo ( $\text{kg/m}^3$ ) e Idade (dias). A saída foi a resistência à compressão e o principal objetivo é comparar dois conjuntos de dados usando três medidas estatísticas bem conhecidas, como RMSE, MSE e  $R^2$ .

Em relação a Etapa 1, referente à análise das bases de dados, destaca-se que:

- Foi realizada a elaboração completa de DATA\_BR2023 desde a limpeza, normalização e padronização, além de uniformizar dados de entrada que foi comparada com DATA\_YEH1998 nas etapas de treinamento e teste;
- A base de dados DATA\_BR2023 pode ser considerada como parâmetro atualizado de traços de concretos para outras modelagens computacionais utilizando ML e está disponível no Apêndice para demais consultas;
- Muitas diferenças comparativas entre as bases de dados pode ser explicada pelo lapso temporal de 25 anos entre as duas pesquisas e o fato de terem sido realizadas em países distintos;
- De acordo com as bases de dados analisadas, no Brasil os concretos têm maior consumo médio de cimento, água, agregados miúdos e graúdos. Apesar disso alcançam resistências à compressão média menor que a base de dados internacional;

Posteriormente, quanto a Etapa 2, na qual ocorreu o treinamento da técnica, pode-se inferir que:

- A divisão em 5 diferentes casos para prever a resistência à compressão com duas bases de dados foi bem sucedida ao abranger todas as possibilidades de interação entre treinamento e teste;
- Ao utilizar somente a base de dados brasileira (Caso 1) para treinamento e teste a diferença entre as resistência à compressão média foi menor do que ao unificar as duas

bases de dados (Caso 5), o que pode indicar que a rede está generalizando bem e que faz sentido a comparação entre as bases de dados.

- Utilizando a técnica de Multilayer Perceptron, as resistências previstas apresentaram maiores desvios-padrões no Caso 2, justificado pelo fato de serem dados coletados da literatura de diversos países e por apresentarem mais instâncias.

Finalmente, em relação a Etapa 3, da análise estatística dos casos apresentados, conclui-se que:

- O Caso 1 (TR\_TE.BR) obteve um  $R^2$  que combinado com um RMSE indica um bom ajuste dentro da área de pesquisa de modelos preditivos em concretos e que pode ser melhorado com a atualização da base de dados brasileira criada;
- O Caso 2, o qual utilizou somente o banco de dados do repositório, e o Caso 5, que unifica as duas bases de dados, foram aqueles que apresentaram melhor desempenho. Ambos os casos apresentaram medidas estatísticas satisfatórias e parâmetros que ainda poderiam ser melhorados com outros modelos de aprendizado de máquina ou novas configurações usando novos bancos de dados;
- Em relação ao Caso 2, em que foram treinados e testados somente DATA\_YEH1998, os resultados foram os melhores;
- A amostra brasileira não generaliza bem para o banco de dados do repositório e vice-versa. O ideal para a modelagem mostrou ser o uso do mesmo banco de dados para treinamento e teste ou, o uso de ambos juntos, como no Caso 5;
- Os dados de entrada mais relevantes para os Casos 2 e 5, com menores erros, foram: o consumo de cimento e a idade, obtidos através da Análise de Importância de Permutação.

Além disso, as vantagens e desvantagens das técnicas apresentadas foram discutidas e comparadas de forma crítica. Foi percebido que o desempenho dos modelos é influenciado por diversos fatores, como a natureza da relação entre os ingredientes da mistura de concreto e sua resistência, o tamanho do conjunto de dados de treinamento e o número de características adotadas no modelo.

Por fim, a revisão do desempenho das técnicas de ML, juntamente com seus benefícios e desvantagens apresentados neste estudo, deve auxiliar na escolha dos modelos adequados para prever a resistência mecânica do concreto. O estudo previu a resistência à compressão do

concreto através da comparação de duas bases de dados, uma internacional denominada DATA\_YEH1998 e outra nacional denominada DATA\_BR2023, por meio de técnicas de Machine Learning e concluiu que utilizar somente a base de dados internacional como treinamento e teste apresenta melhores resultados de desempenho.

.

## 6.2 SUGESTÕES PARA DESENVOLVIMENTOS FUTUROS

Os resultados obtidos nesta investigação podem ser ampliados, dando continuidade às pesquisas relacionadas ao estudo da aplicação de *Machine Learning* em materiais cimentícios, sendo propostos os seguintes desenvolvimentos futuros:

- Realização de novos treinamentos para predição da resistência à compressão do tipos específicos de concretos;
- Buscar a previsão da resistência à compressão de outros tipos de cimento Portland com a substituição do clínquer por materiais cimentícios suplementares (MCS);
- Testar o treinamento com utilização de outras propriedades do cimento como novos inputs;
- Fazer novos treinamentos para previsão das resistências à compressão de amostras de cimento aos 3 e 7 dias;
- Fazer previsão da consistência do concreto utilizando machine learning e comparando com base de dados existente no repositório da UCI;
- Utilizar métodos de deep learning para prever a resistência à compressão de diferentes tipos de concretos;

## REFERÊNCIAS

- ABNT, \_\_\_\_\_. **NBR 5739: Concreto - Ensaio de compressão de corpos de prova cilíndricos**. Rio De Janeiro, 2018.
- ABNT, \_\_\_\_\_. **NBR 7211: Agregados para concreto - Especificação**. Rio de Janeiro, 2005.
- ABNT, \_\_\_\_\_. **NBR 9937: Agregados – Determinação da Absorção e da Massa específica de agregado graúdo**. Rio de Janeiro, 1987.
- ABNT, \_\_\_\_\_. **NBR NM 27 Agregados – Redução da amostra de campo para ensaios de laboratório**. Rio de Janeiro, 2001.
- ABNT, \_\_\_\_\_. **NBR 16697: Cimento Portland – Requisitos**. Rio de Janeiro, 2018.
- AFRICANO, N.; JAVARONI, C.; MANZOLI, O. **Avaliação do uso do agregado graúdo reciclado de resíduo de construção e demolição para uso em concreto estrutural**. In: 62 Congresso Brasileiro do Concreto, 2020, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2020.
- AHMAD, Ayaz; AHMAD, Waqas; ASLAM, Fahid; JOYKLAD, Panuwat. Compressive strength prediction of fly ash-based geopolymers concrete via advanced machine learning techniques. **Case Studies In Construction Materials**, [S.L.], v. 16, n. 05, p. 327-345, 01 jun. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.cscm.2021.e00840>.
- AIM, R. B. LE GOFF, P. Effet de paroi dans les empilements désordonnés de sphères et application à la porosité de mélanges binaires, **Powder Technol.** 1 (5) (1968) 281–290
- AIYER, Bhairevi Ganesh; KIM, Dookie; KARINGATTIKKAL, Nithin; SAMUI, Pijush; RAO, P. Ramamohan. Prediction of compressive strength of self-compacting concrete using least square support vector machine and relevance vector machine. **Ksce Journal Of Civil Engineering**, [S.L.], v. 18, n. 6, p. 1753-1758, 20 jun. 2014. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12205-014-0524-0>.
- ALTUN, Fatih; KIŞI, Özgür; AYDIN, Kamil. Predicting the compressive strength of steel fiber added lightweight concrete using neural network. **Computational Materials Science**, [S.L.], v. 42, n. 2, p. 259-265, abr. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.commatsci.2007.07.011>.
- ALVES, L. C.; COSTA, M. S. M.; SOUZA, R. E. PAULA; M.C. **Estudo da utilização de adições minerais na redução de cimento portland**. In: 62 Congresso Brasileiro do Concreto, 2020, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2020.
- AMANI, J.; MOEINI, R.. Prediction of shear strength of reinforced concrete beams using adaptive neuro-fuzzy inference system and artificial neural network. **Scientia Iranica**, [S.L.], v. 19, n. 2, p. 242-248, abr. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.scient.2012.02.009>.
- AMARAL, L.; QUEIROZ, G.; CAVALCANTI, B.; ALCÂNTARA, L.; ARAÚJO, M.; LAURSEN. **Análise da substituição parcial da areia de pet nas propriedades do concreto convencional**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

ANDRADE, Jonata Jefferson. Técnicas de Inteligência Computacional para a previsão de propriedades mecânicas do concreto leve. 2016. 39 f. **TCC (Graduação)** - Curso de Ciências da Computação, Departamento de Ciências da Computação, Uffj, Juíz de Fora, 2016.

ANVERSA, Giseli Barbosa. **Concreto usinado: entenda as vantagens e os cuidados necessários com a mistura. entenda as vantagens e os cuidados necessários com a mistura.** 2020. Disponível em: <https://www.sienge.com.br/blog/concreto-usinado/>. Acesso em: 06 fev. 2022.

ASTERIS, Panagiotis G.; MOKOS, Vaseilios G.. Concrete compressive strength using artificial neural networks. **Neural Computing And Applications**, [S.L.], v. 32, n. 15, p. 11807-11826, 10 dez. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00521-019-04663-2>.

ATICI, U.. Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network. **Expert Systems With Applications**, [S.L.], v. 38, n. 8, p. 9609-9618, ago. 2011. Elsevier BV. <http://dx.doi.org/10.1016/j.eswa.2011.01.156>

BAÍÁ, J. F. B.; CAVALCANTE, A. F.; LISBÔA, E. M.; VASCONCELOS, C. V. S. A. **Obtenção de curvas de propriedades de concretos com granulometrias fixas dos agregados e 20 % de adição mineral variando a relação água/cimento.** In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

BARBOSA M. R.; BASTOS. P. S. **Traços de Concreto para obras de pequeno porte.** UNESP, 2008. Disponível em: <[https://wwwp.feb.unesp.br/pbastos/site\\_paulo/Artigo%20Tracos%20Concreto-Paulo%20Bastos.pdf](https://wwwp.feb.unesp.br/pbastos/site_paulo/Artigo%20Tracos%20Concreto-Paulo%20Bastos.pdf)>. Acesso em: 03 jun.2022

BARROS, L. B. **Aplicação de redes neurais artificiais no contexto de estimativa de custos de construção de rodovias.** Universidade de Brasília, 2019

BEHNOOD, Ali; VERIAN, Kho Pin; GHAREHVERAN, Mahsa Modiri. Evaluation of the splitting tensile strength in plain and steel fiber-reinforced concrete based on the compressive strength. **Construction And Building Materials**, [S.L.], v. 98, p. 519-529, nov. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2015.08.124>.

BEKKERMAN, Ron; BILENKO, Mikhail; LANGFORD, John. Scaling Up Machine Learning: introduction. **Scaling Up Machine Learning**, [S.L.], v. 5, n. 8, p. 1-20, 30 dez. 2011. Cambridge University Press. <http://dx.doi.org/10.1017/cbo9781139042918.002>.

BENTO, A.; REIS, M. LEITE, F. LOPES, M.; NEVES, D.; SILVA, D. **utilização da cinza do bagaço da cana-de-açúcar (CBC) como agregado miúdo do concreto.** In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

CAMPOS, H.F.; KLEIN, N.s.; MARQUES FILHO, J.. Comparison of the Silica Fume Content for High-Strength Concrete Production: chemical analysis of the pozzolanic reaction and physical behavior by particle packing. **Materials Research**, [S.L.], v. 23, n. 5, p. 2-13, set. 2020. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1980-5373-mr-2020-0285>.

CASTRO, A. L.; LOPES, H. M. T.; VASCONCELLOS, M. L. S; BERNARDO, L. M. **Produção de concretos convencionais sustentáveis a partir do conceito de empacotamento de partículas**. In: 62 Congresso Brasileiro do Concreto, 2020, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2020.

CHAABENE, Wassim Ben; FLAH, Majdi; NEHDI, Moncef L.. Machine learning prediction of mechanical properties of concrete: critical review. **Construction And Building Materials**, [S.L.], v. 260, p. 119889, nov. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2020.119889>.

CHAVES, J. F. N. **Previsão da resistência a compressão do Cimento Portland Comum com utilização de técnicas de Machine Learning**. Universidade de Brasília, 2022.

CHAVES, J.F.N.; RÊGO, J.H.S.; JUNIOR, F.E.S.; VASQUES, L.P. **Bibliometric Review of Machine Learning Use to Predict the Compressive Strength of Concrete Mixtures Concrete 2021**; Brasília, Brazil, 2021.

CHENG, Shukai; SHUI, Zhonghe; SUN, Tao; YU, Rui; ZHANG, Guozhi; DING, Sha. Effects of fly ash, blast furnace slag and metakaolin on mechanical properties and durability of coral sand concrete. **Applied Clay Science**, [S.L.], v. 141, n. 7, p. 111-117, jun. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.clay.2017.02.026>.

CHOU, Jui-Sheng; CHONG, Wai K.; BUI, Dac-Khuong. Nature-Inspired Metaheuristic Regression System: programming and implementation for civil engineering applications. **Journal Of Computing In Civil Engineering**, [S.L.], v. 30, n. 5, p. 052-067, set. 2016. American Society of Civil Engineers (ASCE). [http://dx.doi.org/10.1061/\(asce\)cp.1943-5487.0000561](http://dx.doi.org/10.1061/(asce)cp.1943-5487.0000561).

CHOU, Jui-Sheng; PHAM, Anh-Duc. Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. **Construction And Building Materials**, [S.L.], v. 49, n. 4, p. 554-563, dez. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2013.08.078>.

CHOU, Jui-Sheng; TSAI, Chih-Fong; PHAM, Anh-Duc; LU, Yu-Hsin. Machine learning in concrete strength simulations: multi-nation data analytics. **Construction And Building Materials**, [S.L.], v. 73, n. 7, p. 771-780, dez. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2014.09.054>.

COELHO, P. H.; FREITAS, G.; SILVA, E.; SILVA, A.; CALAÇO, T. **Análise da influência de fibras de polipropileno no desempenho mecânico do concreto**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

CURTI, Rubens. **Propriedades de Dosagem do Concreto**. 2010. Elaborada por ABCP. Disponível em: [http://www.ime.eb.br/~moniz/matconst2/dosagem\\_abcp.pdf](http://www.ime.eb.br/~moniz/matconst2/dosagem_abcp.pdf). Acesso em: 13 mar. 2022.

D.E. RUMELHART, G.E. HINTON, R.J. WILLIAMS, Learning Internal Representations by Error Propagation, **MIT Press** (1986) 318–362.

DABIRI, H.; FARAMARZI, A.; DALL'ASTA, A.; TONDI, E.; MICOZZI, F. A machine

learning-based analysis for predicting fragility curve parameters of buildings. **J. Build. Eng.** 2022, 62, 105367.

DANTAS, A.T.A.; LEITE, M.B.; DE JESUS NAGAHAMA, K. Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. **Constr. Build. Mater.** 2013, 38, 717–722.

DIAS, Patrick Pereira; JAYASINGHE, Laddu Bhagya; WALDMANN, Daniele. Machine learning in mix design of Miscanthus lightweight concrete. *Construction And Building Materials*, [S.L.], v. 302, p. 124191, out. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2021.124191>.

DUARTE, F. S. ; SILVA, R.M.S ; MELO, A. L. M. S. . **Análise comparativa das propriedades do concreto aditivado com bioaditivo à base do óleo da mamona.** In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

DUGLOKENSKI, J.; RIGO, J.; BRUSCHI, G. J.; BRISOTTO, D. S. **Utilização de resíduos de mármore como substituição ao agregado miúdo no concreto: Avaliação das propriedades mecânicas.** In: 62 Congresso Brasileiro do Concreto, 2020, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2020.

EKANAYAKE, I.u.; MEDDAGE, D.P.P.; RATHNAYAKE, Upaka. A novel approach to explain the black-box nature of machine learning in compressive strength predictions of concrete using Shapley additive explanations (SHAP). **Case Studies In Construction Materials**, [S.L.], v. 16, n. 8, p. 01059-1069, jun. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.cscm.2022.e01059>.

ERIC (Education Resources Information Center). **Advanced Data Analysis from an Elementary Point of View.** NY, USA, 2006 pp: 11-14.

FARIAS, L. S.; SOUZA, P. S. L.; RIBEIRO, J. M. **Análise da absorção do concreto reciclado com resíduo de corte de mármore e granito (rcmg) como adição.** In: 61 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

FENG, De-Cheng; LIU, Zhen-Tao; WANG, Xiao-Dan; CHEN, Yin; CHANG, Jia-Qi; WEI, Dong-Fang; JIANG, Zhong-Ming. Machine learning-based compressive strength prediction for concrete: an adaptive boosting approach. **Construction And Building Materials**, [S.L.], v. 230, n. 5, p. 117000-118000, jan. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2019.117000>.

FERDOSIAN, Iman; CAMÕES, Aires. Eco-efficient ultra-high performance concrete development by means of response surface methodology. **Cement And Concrete Composites**, [S.L.], v. 84, p. 146-156, nov. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.cemconcomp.2017.08.019>.

FERREIRA, Ricardo Rodrigues. **Propriedades mecânicas de concreto produzido com a areia natural e areia artificial.** Goiânia, 2019, 116 f. (Trabalho de Conclusão de Curso apresentado à disciplina de Trabalho de Conclusão de Curso II, do Curso de Bacharelado em Engenharia Civil do Instituto Federal de Educação, Ciência e Tecnologia de Goiás).

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**, 2nd ed.; O'Reiliedia : Sebastopol, CA, USA, 2019.

GONÇALVES, A. L.; SANTOS, S. **Concreto de resistência ordinária com resíduo do beneficiamento do mármore e granito**, In: Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC, 2021, Itajaí, SC. Anais do CONTECC 2021.

GOMES, P. C. C.; BARROS, A. R. **Métodos de dosagem de concreto autoadensável**. São Paulo: PINI, 2009. 165p

GÓRA, Jacek; PIASTA, Wojciech. Impact of mechanical resistance of aggregate on properties of concrete. **Case Studies In Construction Materials**, [S.L.], v. 13, n. 10, p. 438-450, dez. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.cscm.2020.e00438>.

GÜÇLÜER, Kadir; ÖZBEYAZ, Abdurrahman; GÖYMEN, Samet; GÜNAYDĎN, Osman. A comparative investigation using machine learning methods for concrete compressive strength estimation. **Materials Today Communications**, [S.L.], v. 27, n. 9, p. 102278-102289, jun. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.mtcomm.2021.102278>.

GUPTA, Sakshi. Using Artificial Neural Network to Predict the Compressive Strength of Concrete containing Nano-silica. **Civil Engineering And Architecture**, [S.L.], v. 1, n. 3, p. 96-102, out. 2013. Horizon Research Publishing Co., Ltd.. <http://dx.doi.org/10.13189/cea.2013.010306>.

GUPTA, Sanchit; CHAUDHARY, Sandeep. State of the art review on supplementary cementitious materials in India – II: characteristics of scms, effect on concrete and environmental impact. **Journal Of Cleaner Production**, [S.L.], v. 357, p. 131945, jul. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.jclepro.2022.131945>.

HAYRTON, 2021. **Métodos de Ensaio de Concreto Endurecido**. Disponível em: <https://qualidadeonline.wordpress.com/2021/09/15/os-metodos-de-ensaios-do-concreto-endurecido-em-testemunhos-cilindricos/>. Acesso em: 13. Mai. 2023

HOANG, Nhat-Duc. Machine Learning-Based Estimation of the Compressive Strength of Self-Compacting Concrete: a multi-dataset study. Mathematics, [S.L.], v. 10, n. 20, p. 3771-3780, 13 out. 2022. **Materials MDPI** . <http://dx.doi.org/10.3390/math10203771>.

HOANG, Nhat-Duc; PHAM, Anh-Duc; NGUYEN, Quoc-Lam; PHAM, Quang-Nhat. Estimating Compressive Strength of High Performance Concrete with Gaussian Process Regression Model. **Advances In Civil Engineering**, [S.L.], v. 2016, n. 5, p. 1-8, nov. 2016. Hindawi Limited. <http://dx.doi.org/10.1155/2016/2861380>.

I. GOODFELLOW, Y. BENGIO, A. COURVILLE, **Deep Learning**, The MIT Press, 2016.

JUNIOR, R. S. L.; NETO, I. D. N.; SOUZA, J.; DAMASCENO, J. C.; LIMA, L. B.; JUNIOR. J. E. **Avaliação da resistência à compressão simples e diametral em concretos com a inserção de fibras de pet**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

KIOUMARSI, Mahdi; DABIRI, Hamed; KANDIRI, Amirreza; FARHANGI, Visar.

Compressive strength of concrete containing furnace blast slag; optimized machine learning-based models. **Cleaner Engineering And Technology**, [S.L.], v. 13, p. 100604-100618, abr. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.clet.2023.100604>.

KUMAR, Aman; ARORA, Harish Chandra; KAPOOR, Nishant Raj; MOHAMMED, Mazin Abed; KUMAR, Krishna; MAJUMDAR, Arnab; THINNUKOOOL, Orawit. Compressive Strength Prediction of Lightweight Concrete: machine learning models. **Sustainability**, [S.L.], v. 14, n. 4, p. 2404-2415, 19 fev. 2022. MDPI AG. <http://dx.doi.org/10.3390/su14042404>.

KUMAR, Shailendra; BARAI, S.V.. Neural networks modeling of shear strength of SFRC corbels without stirrups. **Applied Soft Computing**, [S.L.], v. 10, n. 1, p. 135-148, jan. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.asoc.2009.06.012>.

LOUZEIRO, Gustavo Rodrigues Miranda (2018). **Avaliação do Ciclo de Vida do Cimento: Análise do Gasto Energético do Cimento LC<sup>3</sup> em comparação aos cimentos Portland CP-I e CP-IV**. Monografia de Projeto Final, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 59p.

LUDWIG, Horst-Michael; ZHANG, Wensheng. Research review of cement clinker chemistry. **Cement And Concrete Research**, [S.L.], v. 78, p. 24-37, dez. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.cemconres.2015.05.018>.

LY, Hai-Bang; NGUYEN, Thuy-Anh; PHAM, Binh Thai. Investigation on factors affecting early strength of high-performance concrete by Gaussian Process Regression. **Plos One**, [S.L.], v. 17, n. 1, p. 0262930-0262945, 27 jan. 2022. Public Library of Science (PLoS). <http://dx.doi.org/10.1371/journal.pone.0262930>.

M. AHMADLOU, H. ADELI, Enhanced probabilistic neural network with local decision circles: a robust classifier, **Integr. Comput. Aided Eng.** 17 (3) (2010) 197–210.

M. GARDNER, S. DORLING, Artificial neural networks (the multilayer perceptron)— a review of applications in the atmospheric sciences, **Atmos. Environ.** 32 (14–15) (1998) 2627–2636.

M. KANEVSKI, A. POZDNOUKHOV, V. TIMONIN, Machine Learning for Spatial Environmental Data: Theory, **Applications and Software**, 2009, <https://doi.org/10.1201/9781439808085>.

M.H. RAFIEI, H. ADELI, A new neural dynamic classification algorithm, IEEE Trans. **Neural Networks Learn. Syst.** 28 (12) (2017) 3074–3083.

MANGALATHU, S.; JANG, H.; HWANG, S.H.; JEON, J.S. Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls. **Eng. Struct.** 2020, 208, 110331.

MARCY, M. C. DE A. **Metodologia baseada em redes Neurais Artificiais para a detecção de danos estruturais**. Universidade de Brasília, 2017.

MARSLAND, S. **Machine Learning: an Algorithmic Perspective**, 2014, <https://doi.org/10.1201/b17476>.

MEDEIROS-JUNIOR, R. A.; LIMA, M. G.; MEDEIROS, M. H. F.; REAL, L. V.. Investigação da resistência à compressão e da resistividade elétrica de concretos com diferentes tipos de cimento. **Revista Alconpat**, [S.L.], v. 4, n. 2, p. 113-128, 30 maio 2014. Alconpat Internacional. <http://dx.doi.org/10.21041/ra.v4i2.21>.

MEHDIPOUR, Iman; KHAYAT, Kamal H.. Effect of particle-size distribution and specific surface area of different binder systems on packing density and flow characteristics of cement paste. **Cement And Concrete Composites**, [S.L.], v. 78, p. 120-131, abr. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.cemconcomp.2017.01.005>.

MEHTA, P. K; MONTEIRO, P. J. M. **Concreto – Microestrutura, Propriedades e Materiais**. 2a ed. São Paulo, 2014

MISHIMA, J.; CAMPOS, A.; PINHEIRO, M; SOUZA, U.; RESENDE, M. **Avaliação do desempenho de concretos obtidos com a incorporação de resíduos de granito**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

MITROPOULOU, C.C.; PAPADRAKAKIS, M. Developing fragility curves based on neural network IDA predictions. **Eng. Struct.** 2011, 33, 3409–3421.

MOEIN, Mohammad Mohtasham; SARADAR, Ashkan; RAHMATI, Komeil; MOUSAVINEJAD, Seyed Hosein Ghasemzadeh; BRISTOW, James; ARAMALI, Vartenie; KARAKOUZIAN, Moses. Predictive models for concrete properties using machine learning and deep learning approaches: a review. **Journal Of Building Engineering**, [S.L.], v. 63, n. 4, p. 105444, jan. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.jobbe.2022.105444>.

MORAES, E. F.; MARTINS, I. R.; NUNES, J. L. A.; SILVA, P. B. A. **Efeito do empacotamento de partículas nas propriedades de concretos produzidos em centrais**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

MOTA, J. M.; BARBOSA, F. R.; SANTOS, A. M. LIMA, M. J. S. **Influência da pozolana metacaulim nas propriedades do concreto**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

MUELLER, T.; KUSNE, A. G.; RAMPRASAD, R. Machine Learning in Materials Science: Recent Progress and Emerging Applications. **Reviews in Computational Chemistry**, v. 29, n. i, p. 186–273, 2016.

MURPHY, Kevin Patrick. Exploiting Technology. **Nature**, [S.L.], v. 217, n. 5133, p. 994-994, mar. 1968. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/217994a0>.

MYLVAGANAM, N.; YOGARAJAH, E. A systematic review and assessment of concrete strength prediction models. **Case Stud. Constr. Mater.** 2023, 18, e01830. <https://doi.org/10.1016/j.cscm.2023.e01830>.

N. SIDDIQUE, H. ADELI, **Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing**, John Wiley & Sons, 2013.

NASCIMENTO, Lucas Costa do. **Análise de viabilidade entre concretos dosados pelos**

**métodos da ABCP/ACI e IPT/USP.** UFRPE, Cabo de Santo Agostinho, v. 5, n. 8, p. 327-345, maio 2019.

NAYAK, Dheeresh Kumar; ABHILASH, P.P.; SINGH, Rahul; KUMAR, Rajesh; KUMAR, Veerendra. Fly ash for sustainable construction: a review of fly ash concrete and its beneficial use case studies. **Cleaner Materials**, [S.L.], v. 6, p. 100143-100153, dez. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.clema.2022.100143>.

NDAHIRWA, Désiré; ZMAMOU, Hafida; LENORMAND, Hélène; LEBLANC, Nathalie. The role of supplementary cementitious materials in hydration, durability and shrinkage of cement-based materials, their environmental and economic benefits: a review. **Cleaner Materials**, [S.L.], v. 5, n. 12, p. 100123, set. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.clema.2022.100123>.

NEVES, Antônio. Tipos de Cimento Portland CP. Disponível em: <https://www.blok.com.br/blog/tipos-de-cimento-portland-cp>. Acesso em: 20 maio 2023.

NEVILLE, A. M. **Propriedades do Concreto**. Bookman, 2016.

NEVILLE, A. M.; BROOKS, J. J. **Tecnologia do concreto**. 2a ed. Porto Alegre: Bookman, 2013.

NGUYEN, Hoang; VU, Thanh; VO, Thuc P.; THAI, Huu-Tai. Efficient machine learning models for prediction of concrete strengths. *Construction and Building Materials*, v. 266, Part B, p. 120950, 10 de janeiro de 2021. DOI: 10.1016/j.conbuildmat.2020.120950.

NIKOO, Mehdi; MOGHADAM, Farshid Torabian; SADOWSKI, Łukasz. Prediction of Concrete Compressive Strength by Evolutionary Artificial Neural Networks. **Advances In Materials Science And Engineering**, [S.L.], v. 2015, p. 1-8, 2015. Hindawi Limited. <http://dx.doi.org/10.1155/2015/849126>.

NUNEZ, Itzel; MARANI, Afshin; FLAH, Majdi; NEHDI, Moncef L.. Estimating compressive strength of modern concrete mixtures using computational intelligence: a systematic review. **Construction And Building Materials**, [S.L.], v. 310, n. 8, p. 125279-125289, dez. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2021.125279>.

OH, Sejong. Predictive case-based feature importance and interaction. **Information Sciences**, [S.L.], v. 593, n. 6, p. 155-176, maio 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.ins.2022.02.003>.

OLIVEIRA, Éder Alves de; FENILLI, Felipe Gustavo. **Estudo de dosagem para determinação de traço de concreto**. Engenharia Civil-Pedra Branca, 2019.

OLIVEIRA, Marília P. de; BARBOSA, Normando P.. Potencialidades de um caulim calcinado como material de substituição parcial do cimento portland em argamassas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S.L.], v. 10, n. 2, p. 490-496, jun. 2006. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1415-43662006000200034>.

ORTOLAN, Tiago Luis Possebon; ANDRADE, Jairo José de Oliveira. ESTUDO DOS CONCRETOS COMPOSTOS COM AGREGADOS GRAÚDOS DE CONSTRUÇÃO E DEMOLIÇÃO: análise da penetração de cloretos. **Congresso Brasileiro de Patologia das**

**Construções**, [S.L.], v. 5, n. 8, p. 327-345, fev. 2022. Associação Brasileira de Patologia das Construções. <http://dx.doi.org/10.4322/cbpat.2022.072>.

ÖZCAN, Fatih; ATIŞ, Cengiz D.; KARAHAN, Okan; UNCUOĞLU, Erdal; TANYILDIZI, Harun. Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete. **Advances In Engineering Software**, [S.L.], v. 40, n. 9, p. 856-863, set. 2009. Elsevier BV. <http://dx.doi.org/10.1016/j.advengsoft.2009.01.005>.

PAIXÃO, Rafael Christian Fonseca da; PENIDO, Rúben El-Katib; CURY, Alexandre Abrahão; MENDES, Júlia Castro. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. **Revista Ibracon de Estruturas e Materiais**, [S.L.], v. 15, n. 5, p. 324-345, dez. 2022. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1983-41952022000500003>.

PAUDEL, Satish; PUDASAINI, Anil; SHRESTHA, Rajesh Kumar; KHAREL, Ekta. Compressive strength of concrete material using machine learning techniques. **Cleaner Engineering And Technology**, [S.L.], v. 15, p. 100661, ago. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.clet.2023.100661>.

PARK, Jun-Ryeol; LEE, Hye-Jin; YANG, Keun-Hyeok; KOOK, Jung-Keun; KIM, Sanghee. Study on Influence of Range of Data in Concrete Compressive Strength with Respect to the Accuracy of Machine Learning with Linear Regression. **Applied Sciences**, [S.L.], v. 11, n. 9, p. 3866-3880, 24 abr. 2021. MDPI AG. <http://dx.doi.org/10.3390/app11093866>.

PENNA, Paulo Camillo. **Vendas de cimento iniciam 2023 em alta**. 2023. Disponível em: <https://abcp.org.br/vendas-de-cimento-iniciam-2023-em-alta/>. Acesso em: 10 jul. 2023

PERERA, R.; BARCHÍN, M.; ARTEAGA, A.; DIEGO, A. de. Prediction of the ultimate strength of reinforced concrete beams FRP-strengthened in shear using neural networks. **Composites Part B: Engineering**, [S.L.], v. 41, n. 4, p. 287-298, jun. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.compositesb.2010.03.003>.

POWERS T. C. Properties of Fresh Concrete, 1968, p. 301.

Q.V. LE, J. NGIAM, A. COATES, A. LAHIRI, B. PROCHNOW, A.Y. Ng, On optimization methods for deep learning, in: Proceedings of the 28th **International Conference on Machine Learning**, ICML'11, 2011, pp. 265–272.

QUARANTA, G.; DE DOMENICO, D.; MONTI, G. Machine-learning-aided improvement of mechanics-based code-conforming shear capacity equation for RC elements with stirrups. **Eng. Struct.** 2022, 267, 114665.

RAMKUMAR, K.B.; RAJKUMAR, P.R. Kannan; AHMMAD, Shaik Noor; JEGAN, M.. A Review on Performance of Self-Compacting Concrete – Use of Mineral Admixtures and Steel Fibres with Artificial Neural Network Application. **Construction And Building Materials**, [S.L.], v. 261, p. 120215, nov. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2020.120215>.

RAMZI, Sanaz; HAJILOO, Hamzeh. The Effects of Supplementary Cementitious Materials (SCMs) on the Residual Mechanical Properties of Concrete after Exposure to High

Temperatures—Review. **Buildings**, [S.L.], v. 13, n. 1, p. 103, 31 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/buildings13010103>.

ROCHA, Stéphanie Oliveira Nina; MAIA, Nilton Alves; CARVALHO JÚNIOR, Álvaro Barbosa de; DIAS, Mikaella Pricila Alves; VELOSO, Renê Rodrigues. Utilização de redes neurais para estimativa da resistência à compressão do concreto simples / Use of neural networks to estimate the compressive strength of simple concrete. **Brazilian Journal Of Development**, [S.L.], v. 6, n. 10, p. 79910-79922, 2020. <Http://dx.doi.org/10.34117/bjdv6n10-424>.

RODRIGUES, Clarissa Ribeiro de Sá; FUCALE, Stela. Dosagem de concretos produzidos com agregado miúdo reciclado de resíduo da construção civil. **Ambiente Construído**, [S.L.], v. 14, n. 1, p. 99-111, mar. 2014. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1678-86212014000100009>.

S.K., Kirthika; SINGH, S.K.; CHOURASIA, Ajay. Alternative fine aggregates in production of sustainable concrete- A review. **Journal Of Cleaner Production**, [S.L.], v. 268, p. 122089, set. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.jclepro.2020.122089>.

SADEGH-ZADEH, S.-A.; DASTMARD, A.; MONTAZERI KAFSHGARKOLAEI, L.; MOVAHEDI, S.; SHIRY GHIDARY, S.; NAJAFI, A.; SAADAT, M. Machine Learning Modelling for Compressive Strength Prediction of Superplasticizer-Based Concrete. **Infrastructures** 2023, 8, 21. <https://doi.org/10.3390/infrastructures8020021>.

SANDRO, M. **Rede Neural Perceptron Multicamadas**. 2018. Disponível em: <https://medium.com/ensina-ai/rede-neural-percep-tron-multicamadas-f9de8471f1a9> Acesso em: 10 Mar 2023.

SANTOS, I.; PELOSO, L. R. **Produção do concreto com resíduo de granito**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

SHANMUGASUNDARAM, N.; PRAVEENKUMAR, S.; GAYATHIRI, K.; DIVYA, S. Prediction on compressive strength of Engineered Cementious composites using Machine learning approach. **Constr. Build. Mater.** 2022, 342, 127933. <http://doi.org/10.1016/j.conbuildmat.2022.127933>.

SHARMA, Meenakshi; BISHNOI, Shashank; MARTIRENA, Fernando; SCRIVENER, Karen. Limestone calcined clay cement and concrete: a state-of-the-art review. **Cement And Concrete Research**, [S.L.], v. 149, p. 106564-106576, nov. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.cemconres.2021.106564>.

SHENKEL, L.; POLESELLO, E. **Efeito das adições minerais no concreto de alto desempenho**. In: .62 Congresso Brasileiro do Concreto, 2020, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2020.

SILVA, A. S. M. DA. **Dosagem de concreto pelos métodos de empacotamento compressível e Aïtcin-Faury modificado**. Dissertação de Mestrado em Ciências em Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2004.

SILVA, L. A.; ARAÚJO, L. B. R.; BEZERRA, A. K. L.; MURTA, A. H. F.; BABADOPULOS,

L. F. de A. L.; MEDEIROS JÚNIOR, M. S. Modelagem preditiva de propriedades mecânicas em concretos reforçados com fibra de aço utilizando redes neurais artificiais. **Ambiente Construído**, Porto Alegre, v. 22, n. 2, p. 215-232, abr./jun. 2022. ISSN 1678-8621 Associação Nacional de Tecnologia do Ambiente Construído. <http://dx.doi.org/10.1590/s1678-86212022000200602>

SILVA, R.V.; BRITO, J. de; DHIR, R.K.. Fresh-state performance of recycled aggregate concrete: a review. **Construction And Building Materials**, [S.L.], v. 178, p. 19-31, jul. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2018.05.149>.

SOBHANI, J.; KHANZADI, M.; MOVAHEDIAN, A.H.. Support vector machine for prediction of the compressive strength of no-slump concrete. **Computers And Concrete**, [S.L.], v. 11, n. 4, p. 337-350, 25 abr. 2013. <http://dx.doi.org/10.12989/CAC.2013.11.4.337>.

SOBRAL, Hernani Sávio. **Propriedades do concreto fresco**. 5.ed. São Paulo, Associação Brasileira de Cimento Portland, 2000. 32p. (ET-15)

SOUSA, M. I. C. **Microestrutura de pastas de cimento ternárias com metacaulim e nanossílica**. Universidade de Brasília, 2019.

SOUZA, L. G.; LIMA, I. A.; RAMOS, J. A.; MARTINS, I. R. **Influência da utilização de escória de alto forno em diferentes teores na substituição do agregado miúdo no concreto convencional**. In: 61 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

TAFFESE, Woubishet Zewdu; SISTONEN, Esko. Machine learning for durability and service-life assessment of reinforced concrete structures: recent advances and future directions. **Automation In Construction**, [S.L.], v. 77, n. 7, p. 1-14, maio 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.autcon.2017.01.016>.

TANARSLAN, H.M.; SECER, M.; KUMANLIOGLU, A.. An approach for estimating the capacity of RC beams strengthened in shear with FRP reinforcements using artificial neural networks. **Construction And Building Materials**, [S.L.], v. 30, p. 556-568, maio 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2011.12.008>.

TORALLES, Berenice Martins; COUTO, Álisson Franco do; NOGUEIRA, Geovana Souza Ferreira; SANDOVAL, Gersson Fernando Barreto; ALVES, Guilherme Perosso; SOUZA, Isabela Cristina de; PAULINO, Rafaella Salvador. Estudo Comparativo de Diferentes Métodos de Dosagem de Concretos Convencionais. **Revista de Engenharia e Tecnologia**, João Pessoa, v. 10, n. 1, p. 184-198, abr. 2018.

TUTIKIAN, Bernardo F.; HELENE, Paulo. Dosagem de Concretos de Cimentos Portland. In: **IBRACON. Concreto: Ciência e Tecnologia**. São Paulo: Ibracon, 2011. p. 1-567.

VAPNIK, V. AND KOTZ, S. **Estimation of Dependences Based on Empirical Data: Empirical Inference Science (Information Science and Statistics)**. Springer-Verlag New York, Inc., 2006. Secaucus, NJ, USA.

VASCONCELOS, A. L. R.; FARIAS, P. B.; JAPIASSU, A. S. O. VIEIRA, D. S.; MATIAS. **Análise da influência de fibras de polipropileno no desempenho mecânico do concreto**. In: 60 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso

Brasileiro do Concreto, 2018.

VIKHAR, Pradnya A.. Evolutionary algorithms: a critical review and its future prospects. 2016 International Conference On Global Trends In Signal Processing, **Information Computing And Communication** (Icgtspicc), [S.L.], v. 6, n. 4, p. 236-250, dez. 2016. IEEE. <http://dx.doi.org/10.1109/icgtspicc.2016.7955308>.

VISEDO, G.; PECCHIO, M. **ROADMAP TECNOLÓGICO DO CIMENTO**: Potencial de redução das emissões de carbono da indústria do cimento brasileira até 2050 / coordenado por Gonzalo Visedo e Marcelo Pecchio. Rio de Janeiro: SNIC, 64 p, 2019

WANG, Dehui; SHI, Caijun; FARZADNIA, Nima; SHI, Zhenguoguo; JIA, Huangfei; OU, Zhihua. A review on use of limestone powder in cement-based materials: mechanism, hydration and microstructures. **Construction and Building Materials**.

WANG, Peng; KE, Lin-Yu-Wen; WU, Hao-Liang; LEUNG, Christopher K.y.. Effects of water-to-cement ratio on the performance of concrete and embedded GFRP reinforcement. **Construction And Building Materials**, [S.L.], v. 351, p. 128833, out. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2022.128833>.

WIDMAR, W. **Concretos com substituição total e parcial do agregado por resíduos de rocha ametista**. In: 61 Congresso Brasileiro do Concreto, 2018, Foz do Iguaçu. Anais do 60 Congresso Brasileiro do Concreto, 2018.

WILLARD, J.; JIA, X.; XU, S.; STEINBACH, M.; KUMAR, V. **Integrating Scientific Knowledge with Machine Learning for Engineering and Environmental Systems**. 2022. Disponível em: <https://arxiv.org/abs/2003.04919v6>. Acesso em: 20 Mai. 2023

X. TAN, H. SUN, F. NAN, Application of Improved BP Algorithm in Prediction of Axial Tension Performance and Crack Width Control Ability of UHPC, 2020 **International Wireless Communications and Mobile Computing**, IWCMC), 2020, pp. 1972–1976.

X. WANG, X. XIE, T.C.E. CHENG, A modified artificial bee colony algorithm for order acceptance in two-machine flow shops, **Int. J. Prod. Econ.** 141 (2013), <https://doi.org/10.1016/j.ijpe.2012.06.003>

XU, B.; TAN, Y.; SUN, W.; MA, T.; LIU, H.; WANG, D. Study on the Prediction of the Uniaxial Compressive Strength of Rock Based on the SSA-XGBoost Model. **Sustainability** 2023, 15, 5201. <https://doi.org/10.3390/su15065201>.(Acess: 20 May 2023)

XU, B.; TAN, Y.; SUN, W.; MA, T.; LIU, H.; WANG, D. Study on the Prediction of the Uniaxial Compressive Strength of Rock Based on the SSA-XGBoost Model. **Sustainability** 2023, 15, 5201. <https://doi.org/10.3390/su15065201>.(Acess: 20 May 2023)

YANG, Li; SHAMI, Abdallah. On hyperparameter optimization of machine learning algorithms: theory and practice. **Neurocomputing**, [S.L.], v. 415, p. 295-316, nov. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2020.07.061>.

YEH, I.-C. A mix Proportioning Methodology for Fly Ash and Slag Concrete Using Artificial Neural Networks. **Chung Hua J. Sci. Eng.** 2003, 1, 77–84.

YEH, I.-C. Analysis of strength of concrete using design of experiments and neural networks. **J. Mater. Civ. Eng.** 2006, 18, 597–604.

YEH, I.-C. Design of High Performance Concrete Mixture Using Neural Networks. **J. Comput. Civ. Eng.** 1999, 13, 36–42.

YEH, I.-C. Modeling Concrete Strength with Augment-Neuron Networks. *J. Mater. Civ. Eng.* 1998, 10, 263–268.

YEH, I.-C. Modeling of strength of high-performance concrete using artificial neural networks. **Cem. Concr. Res.** 1998, 28, 1797–1808. [http://doi.org/10.1016/s0008-8846\(98\)00165-3](http://doi.org/10.1016/s0008-8846(98)00165-3).

YEH, I.-C. Prediction of Strength of Fly Ash and Slag Concrete By The Use of Artificial Neural Networks. **J. Chin. Inst. Civ. Hydraul. Eng.** 2003, 15, 659–663.

YOUNG, Benjamin A.; HALL, Alex; PILON, Laurent; GUPTA, Puneet; SANT, Gaurav. Can the compressive strength of concrete be estimated from knowledge of the mixture proportions?: new insights from statistical analysis and machine learning methods. **Cement And Concrete Research**, [S.L.], v. 115, p. 379-388, jan. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.cemconres.2018.09.006>.

ZEINI, Husein Ali; AL-JEZNAWI, Duaa; IMRAN, Hamza; BERNARDO, Luís Filipe Almeida; AL-KHAFAJI, Zainab; OSTROWSKI, Krzysztof Adam. Random Forest Algorithm for the Strength Prediction of Geopolymer Stabilized Clayey Soil. **Sustainability**, [S.L.], v. 15, n. 2, p. 1408-1418, 11 jan. 2023. MDPI AG. <http://dx.doi.org/10.3390/su15021408>.

ZHANG, J.; LI, D.; WANG, Y. Toward intelligent construction: Prediction of mechanical properties of manufactured-sand concrete using tree-based models. **J. Clean. Prod.** 2020, 258, 120665.

ZHANG, Junfei; MA, Guowei; HUANG, Yimiao; SUN, Junbo; ASLANI, Farhad; NENER, Brett. Modelling uniaxial compressive strength of lightweight self-compacting concrete using random forest regression. **Construction And Building Materials**, [S.L.], v. 210, p. 713-719, jun. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.conbuildmat.2019.03.189>.

ZHOU, Min; WU, Zemei; OUYANG, Xue; HU, Xiang; SHI, Caijun. Mixture design methods for ultra-high-performance concrete - a review. **Cement And Concrete Composites**, [S.L.], v. 124, p. 104242, nov. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.cemconcomp.2021.104242>.

ZIOLKOWSKI, Patryk; NIEDOSTATKIEWICZ, Maciej. Machine Learning Techniques in Concrete Mix Design. **Materials**, [S.L.], v. 12, n. 8, p. 1256, 17 abr. 2019. MDPI AG. <http://dx.doi.org/10.3390/ma12081256>.

**APÊNDICE A – Banco de Dados Brasileiro (DATA\_BR23)**

| <b>Dados de Entrada Utilizados</b> |                         |            |                                       |                                       |                                    |                                       |   |  |                         |   |
|------------------------------------|-------------------------|------------|---------------------------------------|---------------------------------------|------------------------------------|---------------------------------------|---|--|-------------------------|---|
|                                    | <b>Autor</b>            | <b>Ano</b> | <b>Cimento<br/>(kg/m<sup>3</sup>)</b> | <b>Escória<br/>(kg/m<sup>3</sup>)</b> | <b>Água<br/>(kg/m<sup>3</sup>)</b> | <b>Aditivo<br/>(kg/m<sup>3</sup>)</b> | <b>Agregado<br/>graúdo<br/>(kg/m<sup>3</sup>)</b> | <b>Agregado<br/>miúdo<br/>(kg/m<sup>3</sup>)</b> | <b>Idade<br/>(dias)</b> | <b>Resistência à<br/>compressão<br/>(MPa)</b> |
| 1                                  | Africano <i>et al.</i>  | 2020       | 269.78                                | 0.00                                  | 180.95                             | 0.00                                  | 904.75  | 865.27   | 28.00                   | 29.44   |
| 2                                  | Alves <i>et al.</i>     | 2020       | 223.04                                | 0.00                                  | 204.00                             | 2.18                                  | 1098.06   | 850.00   | 28.00                   | 30.80   |
| 3                                  | Alves <i>et al.</i>     | 2020       | 223.04                                | 0.00                                  | 204.00                             | 2.18                                  | 1098.06   | 850.00   | 28.00                   | 30.80   |
| 4                                  | Alves <i>et al.</i>     | 2020       | 223.04                                | 0.00                                  | 204.00                             | 2.18                                  | 1098.06   | 850.00   | 7.00                    | 23.70   |
| 5                                  | Alves <i>et al.</i>     | 2020       | 223.04                                | 0.00                                  | 204.00                             | 2.18                                  | 1098.06   | 850.00   | 7.00                    | 23.70   |
| 6                                  | Alves <i>et al.</i>     | 2020       | 270.60                                | 0.00                                  | 194.70                             | 2.64                                  | 1099.89   | 792.99   | 28.00                   | 41.90   |
| 7                                  | Alves <i>et al.</i>     | 2020       | 270.60                                | 0.00                                  | 194.70                             | 2.64                                  | 1099.89   | 792.99   | 28.00                   | 41.90   |
| 8                                  | Alves <i>et al.</i>     | 2020       | 270.60                                | 0.00                                  | 194.70                             | 2.64                                  | 1099.89   | 792.99   | 7.00                    | 30.80   |
| 9                                  | Alves <i>et al.</i>     | 2020       | 270.60                                | 0.00                                  | 194.70                             | 2.64                                  | 1099.89   | 792.99   | 7.00                    | 30.80   |
| 10                                 | Amaral <i>et al.</i>    | 2018       | 312.74                                | 0.00                                  | 186.22                             | 2.78                                  | 834.51  | 901.27   | 28.00                   | 42.88   |
| 11                                 | Amaral <i>et al.</i>    | 2018       | 312.74                                | 0.00                                  | 186.22                             | 2.78                                  | 834.51  | 901.27   | 7.00                    | 29.98   |
| 12                                 | Anoni <i>et al.</i>     | 2020       | 254.20                                | 0.00                                  | 146.94                             | 1.55                                  | 1158.78   | 803.21   | 28.00                   | 18.77   |
| 13                                 | Anoni <i>et al.</i>     | 2020       | 265.14                                | 0.00                                  | 145.51                             | 1.62                                  | 1165.99   | 797.05   | 28.00                   | 22.69   |
| 14                                 | Anoni; Trigo; Pietrobon | 2020       | 440.73                                | 0.00                                  | 127.38                             | 2.69                                  | 1129.78   | 547.69   | 28.00                   | 54.21   |
| 15                                 | Araújo <i>et al.</i>    | 2022       | 313.63                                | 0.00                                  | 220.49                             | 0.00                                  | 1060.65   | 722.30   | 28.00                   | 39.09   |
| 16                                 | Baía <i>et al.</i>      | 2018       | 274.97                                | 0.00                                  | 200.00                             | 0.00                                  | 1045.80   | 796.70   | 28.00                   | 26.00   |
| 17                                 | Baía <i>et al.</i>      | 2018       | 274.97                                | 0.00                                  | 200.00                             | 0.00                                  | 1045.80   | 796.70   | 7.00                    | 17.00   |
| 18                                 | Baía <i>et al.</i>      | 2018       | 299.97                                | 0.00                                  | 200.00                             | 0.00                                  | 1045.80   | 770.60   | 28.00                   | 26.00   |
| 19                                 | Baía <i>et al.</i>      | 2018       | 299.97                                | 0.00                                  | 200.00                             | 0.00                                  | 1045.80   | 770.60   | 7.00                    | 21.00   |
| 20                                 | Baía <i>et al.</i>      | 2018       | 314.33                                | 0.00                                  | 200.00                             | 0.00                                  | 1045.80   | 755.70   | 28.00                   | 31.00   |

| Dados de Entrada Utilizados |                       |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|-----------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                 | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 21                          | Baía <i>et al.</i>    | 2018 | 314.33                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 755.70                              | 7.00         | 21.00                          |
| 22                          | Baía <i>et al.</i>    | 2018 | 330.00                       | 88.00                        | 228.80                    | 0.00                         | 860.20                               | 710.16                              | 28.00        | 31.90                          |
| 23                          | Baía <i>et al.</i>    | 2018 | 330.00                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 739.30                              | 28.00        | 31.00                          |
| 24                          | Baía <i>et al.</i>    | 2018 | 330.00                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 739.30                              | 7.00         | 24.00                          |
| 25                          | Baía <i>et al.</i>    | 2018 | 347.41                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 721.20                              | 28.00        | 33.00                          |
| 26                          | Baía <i>et al.</i>    | 2018 | 347.41                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 721.20                              | 7.00         | 24.50                          |
| 27                          | Baía <i>et al.</i>    | 2018 | 366.63                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 701.10                              | 28.00        | 34.00                          |
| 28                          | Baía <i>et al.</i>    | 2018 | 366.63                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 701.10                              | 7.00         | 27.00                          |
| 29                          | Baía <i>et al.</i>    | 2018 | 412.50                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 653.30                              | 28.00        | 36.50                          |
| 30                          | Baía <i>et al.</i>    | 2018 | 412.50                       | 0.00                         | 200.00                    | 0.00                         | 1045.80                              | 653.30                              | 7.00         | 29.00                          |
| 31                          | Barbosa <i>et al.</i> | 2020 | 121.50                       | 135.00                       | 219.24                    | 0.00                         | 1044.63                              | 881.55                              | 28.00        | 22.10                          |
| 32                          | Barbosa <i>et al.</i> | 2020 | 121.50                       | 135.00                       | 219.24                    | 0.00                         | 1044.63                              | 881.55                              | 7.00         | 14.80                          |
| 33                          | Barbosa <i>et al.</i> | 2020 | 180.00                       | 200.00                       | 207.60                    | 0.00                         | 1052.40                              | 721.20                              | 28.00        | 27.80                          |
| 34                          | Barbosa <i>et al.</i> | 2020 | 180.00                       | 200.00                       | 207.60                    | 0.00                         | 1052.40                              | 721.20                              | 7.00         | 21.30                          |
| 35                          | Barbosa <i>et al.</i> | 2020 | 225.00                       | 250.00                       | 241.00                    | 0.00                         | 1065.50                              | 584.00                              | 28.00        | 37.10                          |
| 36                          | Barbosa <i>et al.</i> | 2020 | 225.00                       | 250.00                       | 241.00                    | 0.00                         | 1065.50                              | 584.00                              | 7.00         | 30.00                          |
| 37                          | Barros e Pereira      | 2020 | 243.38                       | 0.00                         | 184.97                    | 0.00                         | 1059.94                              | 859.93                              | 28.00        | 30.20                          |
| 38                          | Bastos e Barbosa      | 2005 | 179.25                       | 47.80                        | 203.15                    | 3.59                         | 874.74                               | 920.15                              | 28.00        | 15.00                          |
| 39                          | Bastos e Barbosa      | 2005 | 179.25                       | 47.80                        | 203.15                    | 3.59                         | 874.74                               | 920.15                              | 7.00         | 7.00                           |
| 40                          | Bastos e Barbosa      | 2005 | 201.75                       | 53.80                        | 196.37                    | 4.04                         | 890.39                               | 911.91                              | 28.00        | 20.00                          |
| 41                          | Bastos e Barbosa      | 2005 | 201.75                       | 53.80                        | 196.37                    | 4.04                         | 890.39                               | 911.91                              | 7.00         | 10.00                          |
| 42                          | Bastos e Barbosa      | 2005 | 219.00                       | 58.40                        | 189.80                    | 4.38                         | 905.20                               | 905.20                              | 28.00        | 25.00                          |

| <b>Dados de Entrada Utilizados</b> |                  |            |                                       |                                       |                                    |                                       |   |  |                         |   |
|------------------------------------|------------------|------------|---------------------------------------|---------------------------------------|------------------------------------|---------------------------------------|---|--|-------------------------|---|
|                                    | <b>Autor</b>     | <b>Ano</b> | <b>Cimento<br/>(kg/m<sup>3</sup>)</b> | <b>Escória<br/>(kg/m<sup>3</sup>)</b> | <b>Água<br/>(kg/m<sup>3</sup>)</b> | <b>Aditivo<br/>(kg/m<sup>3</sup>)</b> | <b>Agregado<br/>graúdo<br/>(kg/m<sup>3</sup>)</b> | <b>Agregado<br/>miúdo<br/>(kg/m<sup>3</sup>)</b> | <b>Idade<br/>(dias)</b> | <b>Resistência à<br/>compressão<br/>(MPa)</b> |
| 43                                 | Bastos e Barbosa | 2005       | 219.00                                | 58.40                                 | 189.80                             | 4.38                                  | 905.20  | 905.20   | 7.00                    | 14.00   |
| 44                                 | Bastos e Barbosa | 2005       | 219.38                                | 0.00                                  | 202.50                             | 3.38                                  | 870.75  | 929.25   | 28.00                   | 15.00   |
| 45                                 | Bastos e Barbosa | 2005       | 219.38                                | 0.00                                  | 202.50                             | 3.38                                  | 870.75  | 929.25   | 7.00                    | 11.00   |
| 46                                 | Bastos e Barbosa | 2005       | 237.75                                | 63.40                                 | 183.86                             | 4.76                                  | 919.30  | 903.45   | 28.00                   | 30.00   |
| 47                                 | Bastos e Barbosa | 2005       | 237.75                                | 63.40                                 | 183.86                             | 4.76                                  | 919.30  | 903.45   | 7.00                    | 16.00   |
| 48                                 | Bastos e Barbosa | 2005       | 249.32                                | 0.00                                  | 195.12                             | 4.06                                  | 872.62  | 888.88   | 28.00                   | 15.00   |
| 49                                 | Bastos e Barbosa | 2005       | 249.32                                | 0.00                                  | 195.12                             | 4.06                                  | 872.62  | 888.88   | 7.00                    | 10.00   |
| 50                                 | Bastos e Barbosa | 2005       | 258.00                                | 68.80                                 | 185.76                             | 5.16                                  | 932.24  | 890.96   | 28.00                   | 35.00   |
| 51                                 | Bastos e Barbosa | 2005       | 258.00                                | 68.80                                 | 185.76                             | 5.16                                  | 932.24  | 890.96   | 7.00                    | 20.00   |
| 52                                 | Bastos e Barbosa | 2005       | 258.30                                | 0.00                                  | 204.75                             | 0.00                                  | 1202.04   | 675.05   | 28.00                   | 28.22   |
| 53                                 | Bastos e Barbosa | 2005       | 258.38                                | 0.00                                  | 198.75                             | 3.97                                  | 887.75  | 914.25   | 28.00                   | 20.00   |
| 54                                 | Bastos e Barbosa | 2005       | 258.38                                | 0.00                                  | 198.75                             | 3.97                                  | 887.75  | 914.25   | 7.00                    | 16.00   |
| 55                                 | Bastos e Barbosa | 2005       | 273.75                                | 73.00                                 | 186.15                             | 5.48                                  | 941.70  | 883.30   | 28.00                   | 40.00   |
| 56                                 | Bastos e Barbosa | 2005       | 273.75                                | 73.00                                 | 186.15                             | 5.48                                  | 941.70  | 883.30   | 7.00                    | 23.00   |
| 57                                 | Bastos e Barbosa | 2005       | 280.60                                | 0.00                                  | 192.15                             | 4.58                                  | 890.60  | 878.40   | 28.00                   | 20.00   |
| 58                                 | Bastos e Barbosa | 2005       | 280.60                                | 0.00                                  | 192.15                             | 4.58                                  | 890.60  | 878.40   | 7.00                    | 16.00   |
| 59                                 | Bastos e Barbosa | 2005       | 290.25                                | 77.40                                 | 185.76                             | 5.81                                  | 948.15  | 870.75   | 28.00                   | 45.00   |
| 60                                 | Bastos e Barbosa | 2005       | 290.25                                | 77.40                                 | 185.76                             | 5.81                                  | 948.15  | 870.75   | 7.00                    | 28.00   |
| 61                                 | Bastos e Barbosa | 2005       | 298.35                                | 0.00                                  | 198.90                             | 4.59                                  | 902.70  | 887.40   | 28.00                   | 25.00   |
| 62                                 | Bastos e Barbosa | 2005       | 298.35                                | 0.00                                  | 198.90                             | 4.59                                  | 902.70  | 887.40   | 7.00                    | 22.00   |
| 63                                 | Bastos e Barbosa | 2005       | 302.68                                | 0.00                                  | 187.53                             | 4.94                                  | 904.75  | 871.85   | 28.00                   | 25.00   |
| 64                                 | Bastos e Barbosa | 2005       | 302.68                                | 0.00                                  | 187.53                             | 4.94                                  | 904.75  | 871.85   | 7.00                    | 21.00   |

| Dados de Entrada Utilizados |                       |      |                                 |                                 |                              |                                 |  |   |                 |                                      |
|-----------------------------|-----------------------|------|---------------------------------|---------------------------------|------------------------------|---------------------------------|--|---|-----------------|--------------------------------------|
|                             | Autor                 | Ano  | Cimento<br>(kg/m <sup>3</sup> ) | Escória<br>(kg/m <sup>3</sup> ) | Água<br>(kg/m <sup>3</sup> ) | Aditivo<br>(kg/m <sup>3</sup> ) | Agregado<br>graúdo<br>(kg/m <sup>3</sup> ) | Agregado<br>miúdo<br>(kg/m <sup>3</sup> ) | Idade<br>(dias) | Resistência à<br>compressão<br>(MPa) |
| 65                          | Bastos e Barbosa      | 2005 | 309.00                          | 82.40                           | 185.40                       | 6.18                            | 955.84                                     | 856.96                                    | 28.00           | 50.00                                |
| 66                          | Bastos e Barbosa      | 2005 | 309.00                          | 82.40                           | 185.40                       | 6.18                            | 955.84                                     | 856.96                                    | 7.00            | 34.00                                |
| 67                          | Bastos e Barbosa      | 2005 | 328.58                          | 0.00                            | 198.83                       | 5.06                            | 913.27                                     | 872.83                                    | 28.00           | 30.00                                |
| 68                          | Bastos e Barbosa      | 2005 | 328.58                          | 0.00                            | 198.83                       | 5.06                            | 913.27                                     | 872.83                                    | 7.00            | 26.00                                |
| 69                          | Bastos e Barbosa      | 2005 | 332.12                          | 0.00                            | 191.33                       | 5.42                            | 916.94                                     | 851.96                                    | 28.00           | 30.00                                |
| 70                          | Bastos e Barbosa      | 2005 | 332.12                          | 0.00                            | 191.33                       | 5.42                            | 916.94                                     | 851.96                                    | 7.00            | 25.00                                |
| 71                          | Bastos e Barbosa      | 2005 | 355.12                          | 0.00                            | 189.14                       | 5.79                            | 930.26                                     | 845.34                                    | 28.00           | 35.00                                |
| 72                          | Bastos e Barbosa      | 2005 | 355.12                          | 0.00                            | 189.14                       | 5.79                            | 930.26                                     | 845.34                                    | 7.00            | 28.00                                |
| 73                          | Bastos e Barbosa      | 2005 | 361.72                          | 0.00                            | 200.34                       | 5.56                            | 923.79                                     | 857.01                                    | 28.00           | 35.00                                |
| 74                          | Bastos e Barbosa      | 2005 | 361.72                          | 0.00                            | 200.34                       | 5.56                            | 923.79                                     | 857.01                                    | 7.00            | 30.00                                |
| 75                          | Bastos e Barbosa      | 2005 | 397.80                          | 0.00                            | 208.08                       | 6.12                            | 930.24                                     | 824.16                                    | 28.00           | 40.00                                |
| 76                          | Bastos e Barbosa      | 2005 | 397.80                          | 0.00                            | 208.08                       | 6.12                            | 930.24                                     | 824.16                                    | 7.00            | 34.00                                |
| 77                          | Bastos e Barbosa      | 2005 | 426.88                          | 0.00                            | 199.52                       | 6.96                            | 941.92                                     | 784.16                                    | 28.00           | 45.00                                |
| 78                          | Bastos e Barbosa      | 2005 | 426.88                          | 0.00                            | 199.52                       | 6.96                            | 941.92                                     | 784.16                                    | 7.00            | 36.00                                |
| 79                          | Bastos e Barbosa      | 2005 | 432.90                          | 0.00                            | 213.12                       | 6.66                            | 936.84                                     | 794.76                                    | 28.00           | 45.00                                |
| 80                          | Bastos e Barbosa      | 2005 | 432.90                          | 0.00                            | 213.12                       | 6.66                            | 936.84                                     | 794.76                                    | 7.00            | 36.00                                |
| 81                          | Bastos e Barbosa      | 2005 | 471.96                          | 0.00                            | 205.20                       | 7.69                            | 949.05                                     | 743.85                                    | 28.00           | 50.00                                |
| 82                          | Bastos e Barbosa      | 2005 | 471.96                          | 0.00                            | 205.20                       | 7.69                            | 949.05                                     | 743.85                                    | 7.00            | 40.00                                |
| 83                          | Bastos e Barbosa      | 2005 | 474.83                          | 0.00                            | 214.28                       | 7.31                            | 944.78                                     | 764.59                                    | 28.00           | 50.00                                |
| 84                          | Bastos e Barbosa      | 2005 | 474.83                          | 0.00                            | 214.28                       | 7.31                            | 944.78                                     | 764.59                                    | 7.00            | 40.00                                |
| 85                          | Batista <i>et al.</i> | 2018 | 240.50                          | 0.00                            | 195.32                       | 2.22                            | 1110.00                                    | 1073.00                                   | 28.00           | 22.40                                |
| 86                          | Batista <i>et al.</i> | 2018 | 240.50                          | 0.00                            | 195.32                       | 2.22                            | 1110.00                                    | 1073.00                                   | 7.00            | 12.40                                |

| Dados de Entrada Utilizados |                           |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|---------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                     | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 87                          | Bueno <i>et al.</i>       | 2019 | 270.23                       | 74.55                        | 205.00                    | 0.93                         | 1017.55                              | 451.00                              | 28.00        | 28.36                          |
| 88                          | Cadore <i>et al.</i>      | 2018 | 305.10                       | 0.00                         | 203.40                    | 0.00                         | 1573.00                              | 127.00                              | 28.00        | 39.70                          |
| 89                          | Cadore <i>et al.</i>      | 2018 | 305.10                       | 0.00                         | 203.40                    | 0.00                         | 1573.00                              | 127.00                              | 7.00         | 29.50                          |
| 90                          | Camara                    | 2020 | 332.87                       | 0.00                         | 184.93                    | 1.48                         | 1020.79                              | 828.46                              | 28.00        | 42.50                          |
| 91                          | Camara                    | 2020 | 332.87                       | 0.00                         | 184.93                    | 1.48                         | 1020.79                              | 828.46                              | 7.00         | 38.10                          |
| 92                          | Carvalho e Motta          | 2019 | 450.00                       | 0.00                         | 200.00                    | 5.00                         | 1210.00                              | 1050.00                             | 28.00        | 23.16                          |
| 93                          | Castro <i>et al.</i>      | 2020 | 372.08                       | 0.00                         | 193.93                    | 0.00                         | 1059.85                              | 744.15                              | 28.00        | 40.20                          |
| 94                          | Castro <i>et al.</i>      | 2020 | 372.08                       | 0.00                         | 193.93                    | 0.00                         | 1059.85                              | 744.15                              | 7.00         | 31.90                          |
| 95                          | Cavalcante <i>et al.</i>  | 2018 | 273.00                       | 0.00                         | 220.00                    | 0.00                         | 1011.28                              | 769.46                              | 28.00        | 23.10                          |
| 96                          | Cavalcante <i>et al.</i>  | 2018 | 273.00                       | 0.00                         | 220.00                    | 0.00                         | 1011.28                              | 769.46                              | 7.00         | 14.33                          |
| 97                          | Cezar; Lustosa; Magalhães | 2019 | 414.09                       | 0.00                         | 276.06                    | 0.00                         | 786.77                               | 694.75                              | 28.00        | 27.46                          |
| 98                          | Cezar; Lustosa; Magalhães | 2019 | 414.09                       | 0.00                         | 276.06                    | 0.00                         | 786.77                               | 694.75                              | 7.00         | 20.63                          |
| 99                          | Cordeiro                  | 2019 | 254.98                       | 70.34                        | 217.00                    | 0.00                         | 911.96                               | 826.50                              | 28.00        | 24.73                          |
| 100                         | Cordeiro                  | 2019 | 254.98                       | 70.34                        | 217.00                    | 0.00                         | 911.96                               | 826.50                              | 7.00         | 18.20                          |
| 101                         | Cordeiro <i>et al.</i>    | 2019 | 284.54                       | 0.00                         | 225.55                    | 0.00                         | 1020.18                              | 714.82                              | 28.00        | 21.30                          |
| 102                         | Cordeiro <i>et al.</i>    | 2019 | 294.38                       | 0.00                         | 197.45                    | 3.59                         | 1055.46                              | 739.54                              | 28.00        | 26.30                          |
| 103                         | Cordeiro <i>et al.</i>    | 2019 | 305.86                       | 0.00                         | 167.85                    | 3.73                         | 1096.62                              | 768.38                              | 28.00        | 45.80                          |
| 104                         | Costa e Cabral            | 2019 | 256.75                       | 0.00                         | 188.02                    | 2.29                         | 1001.72                              | 712.98                              | 28.00        | 37.40                          |
| 105                         | Costa <i>et al.</i>       | 2018 | 254.94                       | 70.33                        | 221.53                    | 0.00                         | 959.98                               | 847.45                              | 28.00        | 19.78                          |
| 106                         | Cury                      | 2020 | 321.75                       | 0.00                         | 195.00                    | 0.00                         | 737.10                               | 799.50                              | 28.00        | 30.03                          |
| 107                         | Cury                      | 2020 | 402.19                       | 0.00                         | 195.00                    | 0.00                         | 463.13                               | 711.75                              | 28.00        | 43.36                          |
| 108                         | Dias <i>et al.</i>        | 2019 | 324.00                       | 0.00                         | 180.00                    | 1.01                         | 966.96                               | 793.80                              | 28.00        | 30.35                          |

| Dados de Entrada Utilizados |                           |      |                                 |                                 |                              |                                 |  |   |                 |                                      |
|-----------------------------|---------------------------|------|---------------------------------|---------------------------------|------------------------------|---------------------------------|--|---|-----------------|--------------------------------------|
|                             | Autor                     | Ano  | Cimento<br>(kg/m <sup>3</sup> ) | Escória<br>(kg/m <sup>3</sup> ) | Água<br>(kg/m <sup>3</sup> ) | Aditivo<br>(kg/m <sup>3</sup> ) | Agregado<br>graúdo<br>(kg/m <sup>3</sup> ) | Agregado<br>miúdo<br>(kg/m <sup>3</sup> ) | Idade<br>(dias) | Resistência à<br>compressão<br>(MPa) |
| 109                         | Dias <i>et al.</i>        | 2019 | 324.00                          | 0.00                            | 180.00                       | 1.01                            | 966.96                                     | 793.80                                    | 7.00            | 24.52                                |
| 110                         | Duarte; Silva; Melo       | 2018 | 510.52                          | 0.00                            | 361.10                       | 1.87                            | 1045.93                                    | 1662.29                                   | 28.00           | 22.79                                |
| 111                         | Duarte; Silva; Melo       | 2018 | 510.52                          | 0.00                            | 361.10                       | 1.87                            | 1045.93                                    | 1662.29                                   | 7.00            | 15.95                                |
| 112                         | Duglozenski <i>et al.</i> | 2020 | 320.10                          | 0.00                            | 194.00                       | 0.00                            | 1158.57                                    | 653.78                                    | 28.00           | 33.77                                |
| 113                         | Fagundes <i>et al.</i>    | 2018 | 245.77                          | 0.00                            | 207.96                       | 0.00                            | 1020.87                                    | 869.63                                    | 28.00           | 35.76                                |
| 114                         | Fagundes <i>et al.</i>    | 2018 | 249.57                          | 0.00                            | 172.78                       | 0.00                            | 1036.69                                    | 883.11                                    | 28.00           | 44.53                                |
| 115                         | Fagundes <i>et al.</i>    | 2018 | 253.51                          | 0.00                            | 136.50                       | 0.00                            | 1053.03                                    | 897.02                                    | 28.00           | 75.17                                |
| 116                         | Farias; Souza; Ribeiro    | 2018 | 402.53                          | 0.00                            | 205.74                       | 0.00                            | 1042.09                                    | 639.57                                    | 28.00           | 55.51                                |
| 117                         | Fernandes <i>et al.</i>   | 2015 | 366.99                          | 0.00                            | 188.20                       | 5.65                            | 1151.78                                    | 730.22                                    | 28.00           | 42.50                                |
| 118                         | Fernandes <i>et al.</i>   | 2015 | 366.99                          | 0.00                            | 188.20                       | 5.65                            | 1151.78                                    | 730.22                                    | 7.00            | 30.00                                |
| 119                         | Ferreira                  | 2019 | 223.47                          | 0.00                            | 242.54                       | 0.00                            | 877.51                                     | 893.87                                    | 28.00           | 16.66                                |
| 120                         | Ferreira                  | 2019 | 223.47                          | 0.00                            | 242.54                       | 0.00                            | 877.51                                     | 893.87                                    | 7.00            | 14.80                                |
| 121                         | Ferreira                  | 2019 | 230.03                          | 0.00                            | 221.61                       | 0.00                            | 903.27                                     | 920.11                                    | 28.00           | 25.66                                |
| 122                         | Ferreira                  | 2019 | 230.03                          | 0.00                            | 221.61                       | 0.00                            | 903.27                                     | 920.11                                    | 7.00            | 21.24                                |
| 123                         | Ferreira                  | 2019 | 288.83                          | 0.00                            | 228.95                       | 0.00                            | 887.62                                     | 852.40                                    | 28.00           | 28.64                                |
| 124                         | Ferreira                  | 2019 | 288.83                          | 0.00                            | 228.95                       | 0.00                            | 887.62                                     | 852.40                                    | 7.00            | 23.38                                |
| 125                         | Ferreira                  | 2019 | 291.88                          | 0.00                            | 210.01                       | 0.00                            | 918.35                                     | 872.08                                    | 28.00           | 32.48                                |
| 126                         | Ferreira                  | 2019 | 291.88                          | 0.00                            | 210.01                       | 0.00                            | 918.35                                     | 872.08                                    | 7.00            | 28.25                                |
| 127                         | Ferreira                  | 2019 | 389.81                          | 0.00                            | 218.67                       | 0.00                            | 922.24                                     | 741.59                                    | 28.00           | 41.54                                |
| 128                         | Ferreira                  | 2019 | 389.81                          | 0.00                            | 218.67                       | 0.00                            | 922.24                                     | 741.59                                    | 28.00           | 39.91                                |
| 129                         | Ferreira                  | 2019 | 389.81                          | 0.00                            | 218.67                       | 0.00                            | 922.24                                     | 741.59                                    | 7.00            | 37.21                                |
| 130                         | Ferreira                  | 2019 | 389.81                          | 0.00                            | 218.67                       | 0.00                            | 922.24                                     | 741.59                                    | 7.00            | 34.60                                |

| Dados de Entrada Utilizados |                         |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|-------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                   | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 131                         | Filho                   | 2019 | 274.70                       | 0.00                         | 201.00                    | 0.00                         | 1075.02                              | 784.91                              | 28.00        | 27.63                          |
| 132                         | Filho                   | 2019 | 274.70                       | 0.00                         | 201.00                    | 0.00                         | 1075.02                              | 784.91                              | 7.00         | 24.12                          |
| 133                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 175.00                    | 0.00                         | 840.00                               | 490.00                              | 28.00        | 31.06                          |
| 134                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 28.00        | 36.70                          |
| 135                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 28.00        | 38.70                          |
| 136                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 28.00        | 31.70                          |
| 137                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 28.00        | 28.60                          |
| 138                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 7.00         | 29.80                          |
| 139                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 7.00         | 27.30                          |
| 140                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 7.00         | 24.70                          |
| 141                         | Filho <i>et al.</i>     | 2019 | 288.75                       | 0.00                         | 159.95                    | 2.80                         | 1019.90                              | 819.35                              | 7.00         | 26.40                          |
| 142                         | Florencio <i>et al.</i> | 2018 | 298.78                       | 0.00                         | 166.59                    | 2.90                         | 999.33                               | 811.46                              | 28.00        | 40.24                          |
| 143                         | Florencio <i>et al.</i> | 2018 | 298.78                       | 0.00                         | 166.59                    | 2.90                         | 999.33                               | 811.46                              | 7.00         | 31.28                          |
| 144                         | Florencio <i>et al.</i> | 2018 | 401.46                       | 0.00                         | 175.18                    | 3.89                         | 1007.08                              | 695.69                              | 28.00        | 53.91                          |
| 145                         | Florencio <i>et al.</i> | 2018 | 401.46                       | 0.00                         | 175.18                    | 3.89                         | 1007.08                              | 695.69                              | 7.00         | 45.57                          |
| 146                         | Florêncio <i>et al.</i> | 2018 | 232.60                       | 0.00                         | 166.34                    | 2.26                         | 972.21                               | 859.82                              | 28.00        | 28.60                          |
| 147                         | Florêncio <i>et al.</i> | 2018 | 232.60                       | 0.00                         | 166.34                    | 2.26                         | 972.21                               | 859.82                              | 7.00         | 19.55                          |
| 148                         | Fonseca                 | 2006 | 364.76                       | 97.27                        | 194.54                    | 0.00                         | 1094.29                              | 607.94                              | 28.00        | 28.28                          |
| 149                         | Fujita                  | 2018 | 280.44                       | 0.00                         | 188.00                    | 2.05                         | 1046.00                              | 772.00                              | 28.00        | 32.53                          |
| 150                         | Furian <i>et al.</i>    | 2022 | 228.38                       | 63.00                        | 173.25                    | 0.00                         | 976.50                               | 787.50                              | 28.00        | 25.32                          |
| 151                         | Furian <i>et al.</i>    | 2022 | 228.38                       | 63.00                        | 173.25                    | 0.00                         | 976.50                               | 787.50                              | 7.00         | 18.40                          |
| 152                         | Garcia <i>et al.</i>    | 2021 | 358.76                       | 0.00                         | 219.24                    | 0.00                         | 1195.86                              | 398.62                              | 28.00        | 30.60                          |

| Dados de Entrada Utilizados |                         |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|-------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                   | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 153                         | Garcia <i>et al.</i>    | 2021 | 358.76                       | 0.00                         | 219.24                    | 0.00                         | 1195.86                              | 398.62                              | 7.00         | 21.70                          |
| 154                         | Golinhaki <i>et al.</i> | 2020 | 406.72                       | 0.00                         | 221.85                    | 2.12                         | 951.49                               | 778.94                              | 28.00        | 48.00                          |
| 155                         | Gonçalves e Santos      | 2021 | 336.20                       | 0.00                         | 184.50                    | 0.06                         | 787.20                               | 180.40                              | 28.00        | 50.63                          |
| 156                         | Gonçalves e Santos      | 2021 | 369.00                       | 0.00                         | 184.50                    | 0.06                         | 787.20                               | 180.40                              | 28.00        | 45.00                          |
| 157                         | Graupmann <i>et al.</i> | 2018 | 287.00                       | 0.00                         | 210.00                    | 0.00                         | 1050.00                              | 700.00                              | 28.00        | 32.67                          |
| 158                         | Graupmann <i>et al.</i> | 2018 | 287.00                       | 0.00                         | 210.00                    | 0.00                         | 1050.00                              | 700.00                              | 7.00         | 16.55                          |
| 159                         | Júnior e Albuquerque    | 2018 | 284.63                       | 0.00                         | 186.30                    | 0.00                         | 997.05                               | 821.10                              | 28.00        | 28.41                          |
| 160                         | Júnior e Albuquerque    | 2018 | 284.63                       | 0.00                         | 186.30                    | 0.00                         | 997.05                               | 821.10                              | 7.00         | 20.75                          |
| 161                         | Júnior <i>et al.</i>    | 2018 | 296.02                       | 0.00                         | 198.55                    | 10.83                        | 916.94                               | 851.96                              | 28.00        | 22.89                          |
| 162                         | Júnior <i>et al.</i>    | 2018 | 296.02                       | 0.00                         | 198.55                    | 10.83                        | 916.94                               | 851.96                              | 7.00         | 17.13                          |
| 163                         | Kramer <i>et al.</i>    | 2020 | 327.86                       | 0.00                         | 226.98                    | 0.88                         | 954.83                               | 954.83                              | 28.00        | 47.41                          |
| 164                         | Laursen <i>et al.</i>   | 2019 | 307.50                       | 0.00                         | 150.00                    | 0.00                         | 1080.00                              | 795.00                              | 28.00        | 30.76                          |
| 165                         | Laursen <i>et al.</i>   | 2019 | 307.50                       | 0.00                         | 150.00                    | 0.00                         | 1080.00                              | 795.00                              | 7.00         | 30.02                          |
| 166                         | Lima <i>et al.</i>      | 2020 | 308.25                       | 0.00                         | 202.08                    | 0.00                         | 1057.30                              | 757.95                              | 28.00        | 31.00                          |
| 167                         | Lira e Anjos            | 2020 | 342.38                       | 0.00                         | 208.74                    | 0.00                         | 971.10                               | 771.90                              | 28.00        | 31.02                          |
| 168                         | Lira e Anjos            | 2020 | 342.38                       | 0.00                         | 208.74                    | 0.00                         | 971.10                               | 771.90                              | 7.00         | 26.10                          |
| 169                         | Lôbo e Silva            | 2021 | 311.60                       | 0.00                         | 190.00                    | 0.00                         | 829.92                               | 951.90                              | 28.00        | 27.39                          |
| 170                         | Lôbo e Silva            | 2021 | 311.60                       | 0.00                         | 190.00                    | 0.00                         | 829.92                               | 951.90                              | 7.00         | 20.35                          |
| 171                         | Lopes <i>et al.</i>     | 2019 | 270.60                       | 0.00                         | 190.24                    | 0.00                         | 1049.60                              | 852.80                              | 28.00        | 27.80                          |
| 172                         | Lopes <i>et al.</i>     | 2019 | 270.60                       | 0.00                         | 190.24                    | 0.00                         | 1049.60                              | 852.80                              | 7.00         | 22.80                          |
| 173                         | Lopes <i>et al.</i>     | 2021 | 360.61                       | 0.00                         | 220.37                    | 0.00                         | 817.39                               | 893.52                              | 28.00        | 40.20                          |
| 174                         | Lopes <i>et al.</i>     | 2021 | 360.61                       | 0.00                         | 220.37                    | 0.00                         | 817.39                               | 893.52                              | 7.00         | 28.00                          |

| Dados de Entrada Utilizados |                             |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|-----------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                       | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 175                         | Lopes; Rodrigues; Piovesan  | 2018 | 363.12                       | 0.00                         | 189.26                    | 0.00                         | 968.31                               | 880.28                              | 28.00        | 26.11                          |
| 176                         | Lovatel <i>et al.</i>       | 2020 | 299.30                       | 0.00                         | 208.05                    | 0.00                         | 1029.30                              | 795.70                              | 28.00        | 27.00                          |
| 177                         | Luiz; Cavalcante; Maia      | 2020 | 404.72                       | 0.00                         | 222.10                    | 0.00                         | 1105.57                              | 656.43                              | 28.00        | 39.44                          |
| 178                         | Luiz; Cavalcante; Maia      | 2020 | 404.72                       | 0.00                         | 222.10                    | 0.00                         | 1105.57                              | 656.43                              | 7.00         | 33.83                          |
| 179                         | Maciel; Coelho; Pereira     | 2020 | 375.38                       | 0.00                         | 184.28                    | 0.09                         | 924.56                               | 848.58                              | 28.00        | 34.01                          |
| 180                         | Maculan e Mascolo           | 2019 | 171.69                       | 0.00                         | 158.48                    | 1.32                         | 929.77                               | 787.14                              | 28.00        | 28.20                          |
| 181                         | Maculan e Mascolo           | 2019 | 171.69                       | 0.00                         | 158.48                    | 1.32                         | 929.77                               | 787.14                              | 7.00         | 18.14                          |
| 182                         | Maculan e Mascolo           | 2019 | 212.00                       | 0.00                         | 150.03                    | 1.63                         | 919.74                               | 711.01                              | 28.00        | 34.58                          |
| 183                         | Maculan e Mascolo           | 2019 | 212.00                       | 0.00                         | 150.03                    | 1.63                         | 919.74                               | 711.01                              | 7.00         | 23.59                          |
| 184                         | Maculan e Mascolo           | 2019 | 265.66                       | 0.00                         | 171.65                    | 2.04                         | 862.36                               | 568.09                              | 28.00        | 42.57                          |
| 185                         | Maculan e Mascolo           | 2019 | 265.66                       | 0.00                         | 171.65                    | 2.04                         | 862.36                               | 568.09                              | 7.00         | 28.58                          |
| 186                         | Martins <i>et al.</i>       | 2019 | 339.30                       | 0.00                         | 207.35                    | 1.13                         | 947.78                               | 790.95                              | 7.00         | 25.63                          |
| 187                         | Matos                       | 2019 | 477.00                       | 0.00                         | 205.11                    | 1.59                         | 701.72                               | 930.15                              | 28.00        | 47.70                          |
| 188                         | Medeiros <i>et al.</i>      | 2021 | 405.99                       | 0.00                         | 198.48                    | 1.91                         | 974.38                               | 739.80                              | 28.00        | 55.90                          |
| 189                         | Medeiros <i>et al.</i>      | 2021 | 477.75                       | 0.00                         | 205.80                    | 4.90                         | 1112.30                              | 654.64                              | 28.00        | 48.70                          |
| 190                         | Medeiros <i>et al.</i>      | 2021 | 477.75                       | 0.00                         | 205.80                    | 4.90                         | 1112.30                              | 654.64                              | 7.00         | 45.90                          |
| 191                         | Meert; Hastenpflug; Andrade | 2020 | 466.66                       | 0.00                         | 222.96                    | 0.00                         | 877.32                               | 797.47                              | 28.00        | 51.71                          |
| 192                         | Meert; Hastenpflug; Andrade | 2020 | 466.66                       | 0.00                         | 222.96                    | 0.00                         | 877.32                               | 797.47                              | 7.00         | 40.57                          |
| 193                         | Melo <i>et al.</i>          | 2018 | 157.33                       | 43.40                        | 185.75                    | 0.87                         | 1024.00                              | 950.00                              | 28.00        | 19.80                          |
| 194                         | Melo <i>et al.</i>          | 2018 | 157.33                       | 43.40                        | 185.75                    | 0.87                         | 1024.00                              | 950.00                              | 7.00         | 13.00                          |
| 195                         | Melo <i>et al.</i>          | 2018 | 160.23                       | 44.20                        | 192.05                    | 0.88                         | 1017.00                              | 943.00                              | 28.00        | 24.10                          |
| 196                         | Melo <i>et al.</i>          | 2018 | 160.23                       | 44.20                        | 192.05                    | 0.88                         | 1017.00                              | 943.00                              | 7.00         | 17.00                          |

| Dados de Entrada Utilizados |                    |      |                                 |                                 |                              |                                 |  |   |                 |                                      |
|-----------------------------|--------------------|------|---------------------------------|---------------------------------|------------------------------|---------------------------------|--|---|-----------------|--------------------------------------|
|                             | Autor              | Ano  | Cimento<br>(kg/m <sup>3</sup> ) | Escória<br>(kg/m <sup>3</sup> ) | Água<br>(kg/m <sup>3</sup> ) | Aditivo<br>(kg/m <sup>3</sup> ) | Agregado<br>graúdo<br>(kg/m <sup>3</sup> ) | Agregado<br>miúdo<br>(kg/m <sup>3</sup> ) | Idade<br>(dias) | Resistência à<br>compressão<br>(MPa) |
| 197                         | Melo <i>et al.</i> | 2018 | 162.40                          | 44.80                           | 189.73                       | 0.90                            | 1026.00                                    | 951.00                                    | 28.00           | 24.30                                |
| 198                         | Melo <i>et al.</i> | 2018 | 162.40                          | 44.80                           | 189.73                       | 0.90                            | 1026.00                                    | 951.00                                    | 7.00            | 19.90                                |
| 199                         | Melo <i>et al.</i> | 2018 | 163.85                          | 45.20                           | 184.19                       | 0.90                            | 1028.00                                    | 954.00                                    | 28.00           | 28.10                                |
| 200                         | Melo <i>et al.</i> | 2018 | 163.85                          | 45.20                           | 184.19                       | 0.90                            | 1028.00                                    | 954.00                                    | 7.00            | 20.30                                |
| 201                         | Melo <i>et al.</i> | 2018 | 193.58                          | 53.40                           | 182.09                       | 1.07                            | 1050.00                                    | 901.00                                    | 28.00           | 29.50                                |
| 202                         | Melo <i>et al.</i> | 2018 | 193.58                          | 53.40                           | 182.09                       | 1.07                            | 1050.00                                    | 901.00                                    | 7.00            | 21.70                                |
| 203                         | Melo <i>et al.</i> | 2018 | 197.20                          | 54.40                           | 181.97                       | 1.09                            | 1050.00                                    | 900.00                                    | 28.00           | 35.20                                |
| 204                         | Melo <i>et al.</i> | 2018 | 197.20                          | 54.40                           | 181.97                       | 1.09                            | 1050.00                                    | 900.00                                    | 7.00            | 26.90                                |
| 205                         | Melo <i>et al.</i> | 2018 | 198.65                          | 54.80                           | 183.58                       | 1.10                            | 1052.00                                    | 902.00                                    | 28.00           | 37.40                                |
| 206                         | Melo <i>et al.</i> | 2018 | 198.65                          | 54.80                           | 179.74                       | 1.10                            | 1044.00                                    | 895.00                                    | 28.00           | 38.40                                |
| 207                         | Melo <i>et al.</i> | 2018 | 198.65                          | 54.80                           | 183.58                       | 1.10                            | 1052.00                                    | 902.00                                    | 7.00            | 24.80                                |
| 208                         | Melo <i>et al.</i> | 2018 | 198.65                          | 54.80                           | 179.74                       | 1.10                            | 1044.00                                    | 895.00                                    | 7.00            | 29.00                                |
| 209                         | Melo <i>et al.</i> | 2018 | 249.40                          | 68.80                           | 184.04                       | 1.38                            | 1060.00                                    | 807.00                                    | 28.00           | 38.90                                |
| 210                         | Melo <i>et al.</i> | 2018 | 249.40                          | 68.80                           | 184.04                       | 1.38                            | 1060.00                                    | 807.00                                    | 7.00            | 26.00                                |
| 211                         | Melo <i>et al.</i> | 2018 | 256.65                          | 70.80                           | 186.91                       | 1.42                            | 1064.00                                    | 810.00                                    | 28.00           | 40.70                                |
| 212                         | Melo <i>et al.</i> | 2018 | 256.65                          | 70.80                           | 184.08                       | 1.42                            | 1068.00                                    | 813.00                                    | 28.00           | 43.50                                |
| 213                         | Melo <i>et al.</i> | 2018 | 256.65                          | 70.80                           | 186.91                       | 1.42                            | 1064.00                                    | 810.00                                    | 7.00            | 33.00                                |
| 214                         | Melo <i>et al.</i> | 2018 | 256.65                          | 70.80                           | 184.08                       | 1.42                            | 1068.00                                    | 813.00                                    | 7.00            | 30.80                                |
| 215                         | Melo <i>et al.</i> | 2018 | 260.28                          | 71.80                           | 183.09                       | 1.44                            | 1070.00                                    | 815.00                                    | 28.00           | 48.90                                |
| 216                         | Melo <i>et al.</i> | 2018 | 260.28                          | 71.80                           | 183.09                       | 1.44                            | 1070.00                                    | 815.00                                    | 7.00            | 36.60                                |
| 217                         | Melo <i>et al.</i> | 2020 | 325.88                          | 0.00                            | 181.70                       | 3.00                            | 1113.90                                    | 714.95                                    | 28.00           | 39.80                                |
| 218                         | Melo <i>et al.</i> | 2018 | 348.72                          | 96.20                           | 201.06                       | 1.92                            | 1058.00                                    | 651.00                                    | 28.00           | 43.80                                |

| Dados de Entrada Utilizados |                        |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                  | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 219                         | Melo <i>et al.</i>     | 2018 | 348.72                       | 96.20                        | 201.06                    | 1.92                         | 1058.00                              | 651.00                              | 7.00         | 38.00                          |
| 220                         | Melo <i>et al.</i>     | 2018 | 363.22                       | 100.20                       | 190.88                    | 2.00                         | 1078.00                              | 664.00                              | 28.00        | 53.90                          |
| 221                         | Melo <i>et al.</i>     | 2018 | 363.22                       | 100.20                       | 190.88                    | 2.00                         | 1078.00                              | 664.00                              | 7.00         | 44.10                          |
| 222                         | Melo <i>et al.</i>     | 2018 | 364.68                       | 100.60                       | 190.64                    | 2.01                         | 1080.00                              | 664.00                              | 28.00        | 52.90                          |
| 223                         | Melo <i>et al.</i>     | 2018 | 364.68                       | 100.60                       | 192.15                    | 2.01                         | 1072.00                              | 660.00                              | 28.00        | 55.40                          |
| 224                         | Melo <i>et al.</i>     | 2018 | 364.68                       | 100.60                       | 190.64                    | 2.01                         | 1080.00                              | 664.00                              | 7.00         | 43.80                          |
| 225                         | Melo <i>et al.</i>     | 2018 | 364.68                       | 100.60                       | 192.15                    | 2.01                         | 1072.00                              | 660.00                              | 7.00         | 45.00                          |
| 226                         | Mendes <i>et al.</i>   | 2018 | 327.76                       | 0.00                         | 205.00                    | 0.00                         | 973.34                               | 774.70                              | 28.00        | 30.50                          |
| 227                         | Mendes <i>et al.</i>   | 2018 | 327.76                       | 0.00                         | 205.00                    | 0.00                         | 973.34                               | 774.70                              | 7.00         | 23.00                          |
| 228                         | Mendonça               | 2018 | 273.88                       | 0.00                         | 207.08                    | 0.00                         | 1002.00                              | 668.00                              | 7.00         | 14.06                          |
| 229                         | Mishima <i>et al.</i>  | 2018 | 341.90                       | 0.00                         | 207.22                    | 0.00                         | 1089.95                              | 675.52                              | 28.00        | 24.70                          |
| 230                         | Mishima <i>et al.</i>  | 2018 | 341.90                       | 0.00                         | 207.22                    | 0.00                         | 1089.95                              | 675.52                              | 7.00         | 22.10                          |
| 231                         | Moraes e Lopes         | 2010 | 239.30                       | 0.00                         | 122.25                    | 0.02                         | 491.61                               | 418.78                              | 28.00        | 26.99                          |
| 232                         | Moraes e Lopes         | 2010 | 239.30                       | 0.00                         | 122.25                    | 0.02                         | 491.61                               | 418.78                              | 7.00         | 24.45                          |
| 233                         | Moraes e Lopes         | 2010 | 446.06                       | 0.00                         | 276.36                    | 0.03                         | 1221.80                              | 1202.41                             | 28.00        | 19.63                          |
| 234                         | Moraes e Lopes         | 2010 | 446.06                       | 0.00                         | 276.36                    | 0.03                         | 1221.80                              | 1202.41                             | 7.00         | 17.57                          |
| 235                         | Moreira <i>et al.</i>  | 2018 | 284.63                       | 0.00                         | 186.30                    | 0.00                         | 1035.00                              | 690.00                              | 28.00        | 34.03                          |
| 236                         | Moreira <i>et al.</i>  | 2018 | 284.63                       | 0.00                         | 186.30                    | 0.00                         | 1035.00                              | 690.00                              | 7.00         | 29.25                          |
| 237                         | Munareto <i>et al.</i> | 2019 | 207.35                       | 0.00                         | 175.45                    | 0.00                         | 974.86                               | 844.07                              | 7.00         | 33.10                          |
| 238                         | Nbiya                  | 2019 | 268.25                       | 74.00                        | 244.20                    | 12.21                        | 1110.00                              | 740.00                              | 28.00        | 20.00                          |
| 239                         | Nbiya                  | 2019 | 268.25                       | 74.00                        | 203.50                    | 5.55                         | 1110.00                              | 740.00                              | 28.00        | 23.70                          |
| 240                         | Nbiya                  | 2019 | 268.25                       | 74.00                        | 185.00                    | 9.25                         | 1110.00                              | 740.00                              | 28.00        | 37.70                          |

| Dados de Entrada Utilizados |                         |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|-------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                   | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 241                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 185.00                    | 9.25                         | 1110.00                              | 740.00                              | 28.00        | 28.70                          |
| 242                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 185.00                    | 7.40                         | 1110.00                              | 740.00                              | 28.00        | 27.44                          |
| 243                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 244.20                    | 12.21                        | 1110.00                              | 740.00                              | 7.00         | 14.00                          |
| 244                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 203.50                    | 5.55                         | 1110.00                              | 740.00                              | 7.00         | 15.60                          |
| 245                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 185.00                    | 9.25                         | 1110.00                              | 740.00                              | 7.00         | 32.30                          |
| 246                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 185.00                    | 9.25                         | 1110.00                              | 740.00                              | 7.00         | 18.65                          |
| 247                         | Nbiya                   | 2019 | 268.25                       | 74.00                        | 185.00                    | 7.40                         | 1110.00                              | 740.00                              | 7.00         | 17.84                          |
| 248                         | Negredo                 | 2018 | 337.04                       | 0.00                         | 187.25                    | 0.82                         | 1078.53                              | 793.92                              | 28.00        | 45.74                          |
| 249                         | Negredo                 | 2018 | 337.04                       | 0.00                         | 187.25                    | 0.82                         | 1078.53                              | 793.92                              | 7.00         | 43.38                          |
| 250                         | Pelisser <i>et al.</i>  | 2018 | 365.84                       | 0.00                         | 223.57                    | 0.00                         | 979.64                               | 707.29                              | 28.00        | 40.95                          |
| 251                         | Pelisser <i>et al.</i>  | 2018 | 365.84                       | 0.00                         | 223.57                    | 0.00                         | 979.64                               | 707.29                              | 7.00         | 30.13                          |
| 252                         | Pena <i>et al.</i>      | 2018 | 298.55                       | 0.00                         | 183.70                    | 1.40                         | 1102.30                              | 734.80                              | 28.00        | 31.24                          |
| 253                         | Pereira                 | 2021 | 340.10                       | 93.82                        | 215.79                    | 3.14                         | 882.85                               | 785.74                              | 28.00        | 46.30                          |
| 254                         | Pereira                 | 2021 | 340.10                       | 93.82                        | 215.79                    | 3.14                         | 882.85                               | 785.74                              | 7.00         | 42.60                          |
| 255                         | Pini; Formagini; Cheung | 2018 | 232.00                       | 64.00                        | 185.60                    | 1.73                         | 1146.00                              | 868.00                              | 28.00        | 30.20                          |
| 256                         | Pini; Formagini; Cheung | 2018 | 232.00                       | 64.00                        | 185.60                    | 1.73                         | 1146.00                              | 868.00                              | 7.00         | 21.90                          |
| 257                         | Polastre <i>et al.</i>  | 2018 | 501.87                       | 0.00                         | 167.29                    | 2.79                         | 997.06                               | 815.82                              | 28.00        | 78.88                          |
| 258                         | Polastre <i>et al.</i>  | 2018 | 501.87                       | 0.00                         | 167.29                    | 2.79                         | 997.06                               | 815.82                              | 7.00         | 77.24                          |
| 259                         | Ramos e Fabiche         | 2021 | 285.82                       | 78.85                        | 205.00                    | 0.00                         | 1427.11                              | 410.00                              | 28.00        | 20.14                          |
| 260                         | Ramos e Fabiche         | 2021 | 285.82                       | 78.85                        | 205.00                    | 0.00                         | 1427.11                              | 410.00                              | 7.00         | 18.74                          |
| 261                         | Rêgo <i>et al.</i>      | 2020 | 229.60                       | 0.00                         | 192.08                    | 1.90                         | 994.00                               | 861.84                              | 28.00        | 45.47                          |
| 262                         | Rêgo <i>et al.</i>      | 2020 | 229.60                       | 0.00                         | 192.08                    | 1.90                         | 994.00                               | 861.84                              | 7.00         | 38.30                          |

| Dados de Entrada Utilizados |                       |      |                                 |                                 |                              |                                 |  |   |                 |                                      |
|-----------------------------|-----------------------|------|---------------------------------|---------------------------------|------------------------------|---------------------------------|--|---|-----------------|--------------------------------------|
|                             | Autor                 | Ano  | Cimento<br>(kg/m <sup>3</sup> ) | Escória<br>(kg/m <sup>3</sup> ) | Água<br>(kg/m <sup>3</sup> ) | Aditivo<br>(kg/m <sup>3</sup> ) | Agregado<br>graúdo<br>(kg/m <sup>3</sup> ) | Agregado<br>miúdo<br>(kg/m <sup>3</sup> ) | Idade<br>(dias) | Resistência à<br>compressão<br>(MPa) |
| 263                         | Rohden e Lotério      | 2019 | 223.86                          | 0.00                            | 204.75                       | 0.00                            | 1202.02                                    | 709.80                                    | 28.00           | 24.13                                |
| 264                         | Rohden e Lotério      | 2019 | 305.86                          | 0.00                            | 205.15                       | 0.00                            | 1201.81                                    | 627.01                                    | 28.00           | 38.18                                |
| 265                         | Sales <i>et al.</i>   | 2018 | 526.50                          | 0.00                            | 234.00                       | 0.00                            | 994.50                                     | 526.50                                    | 28.00           | 56.21                                |
| 266                         | Sales <i>et al.</i>   | 2018 | 526.50                          | 0.00                            | 234.00                       | 0.00                            | 994.50                                     | 526.50                                    | 7.00            | 43.80                                |
| 267                         | Salvador              | 2013 | 307.13                          | 0.00                            | 207.90                       | 1.26                            | 1020.60                                    | 834.75                                    | 28.00           | 30.10                                |
| 268                         | Santana e Carneiro    | 2020 | 450.00                          | 0.00                            | 249.00                       | 3.70                            | 707.00                                     | 808.00                                    | 28.00           | 36.90                                |
| 269                         | Santana <i>et al.</i> | 2018 | 320.31                          | 0.00                            | 222.44                       | 0.00                            | 1024.99                                    | 754.51                                    | 28.00           | 40.40                                |
| 270                         | Santana <i>et al.</i> | 2018 | 320.31                          | 0.00                            | 222.44                       | 0.00                            | 1024.99                                    | 754.51                                    | 7.00            | 33.50                                |
| 271                         | Santini <i>et al.</i> | 2018 | 333.04                          | 0.00                            | 148.02                       | 1.85                            | 1119.37                                    | 915.85                                    | 28.00           | 55.32                                |
| 272                         | Santos e Peloso       | 2018 | 180.90                          | 201.00                          | 205.02                       | 0.00                            | 1113.94                                    | 628.33                                    | 28.00           | 36.25                                |
| 273                         | Santos e Peloso       | 2018 | 180.90                          | 201.00                          | 205.02                       | 0.00                            | 1113.94                                    | 628.33                                    | 7.00            | 18.54                                |
| 274                         | Saugo <i>et al.</i>   | 2020 | 225.00                          | 0.00                            | 210.00                       | 2.00                            | 1285.00                                    | 745.00                                    | 28.00           | 21.60                                |
| 275                         | Saugo <i>et al.</i>   | 2020 | 225.00                          | 0.00                            | 190.00                       | 2.00                            | 1285.00                                    | 745.00                                    | 28.00           | 29.20                                |
| 276                         | Saugo <i>et al.</i>   | 2020 | 270.00                          | 0.00                            | 200.10                       | 2.40                            | 1284.90                                    | 699.00                                    | 28.00           | 32.90                                |
| 277                         | Saugo <i>et al.</i>   | 2020 | 270.00                          | 0.00                            | 178.50                       | 2.40                            | 1284.90                                    | 699.00                                    | 28.00           | 45.10                                |
| 278                         | Saugo <i>et al.</i>   | 2020 | 315.00                          | 0.00                            | 196.00                       | 2.80                            | 1284.85                                    | 660.10                                    | 28.00           | 35.40                                |
| 279                         | Saugo <i>et al.</i>   | 2020 | 315.00                          | 0.00                            | 166.95                       | 2.80                            | 1284.85                                    | 660.10                                    | 28.00           | 61.50                                |
| 280                         | Schenkel e Polesello  | 2020 | 287.95                          | 0.00                            | 186.06                       | 1.77                            | 930.30                                     | 819.55                                    | 28.00           | 42.90                                |
| 281                         | Schenkel e Polesello  | 2020 | 287.95                          | 0.00                            | 186.06                       | 1.77                            | 930.30                                     | 819.55                                    | 7.00            | 26.90                                |
| 282                         | Shenkel; Polesello    | 2020 | 365.47                          | 0.00                            | 186.06                       | 1.77                            | 930.30                                     | 819.55                                    | 28.00           | 57.90                                |
| 283                         | Shenkel; Polesello    | 2020 | 365.47                          | 0.00                            | 186.06                       | 1.77                            | 930.30                                     | 819.55                                    | 7.00            | 48.50                                |
| 284                         | Silva                 | 2020 | 346.15                          | 0.00                            | 200.00                       | 1.15                            | 1088.45                                    | 673.07                                    | 28.00           | 38.00                                |

| Dados de Entrada Utilizados |                     |      |                                 |                                 |                              |                                 |  |   |                 |                                      |
|-----------------------------|---------------------|------|---------------------------------|---------------------------------|------------------------------|---------------------------------|--|---|-----------------|--------------------------------------|
|                             | Autor               | Ano  | Cimento<br>(kg/m <sup>3</sup> ) | Escória<br>(kg/m <sup>3</sup> ) | Água<br>(kg/m <sup>3</sup> ) | Aditivo<br>(kg/m <sup>3</sup> ) | Agregado<br>graúdo<br>(kg/m <sup>3</sup> ) | Agregado<br>miúdo<br>(kg/m <sup>3</sup> ) | Idade<br>(dias) | Resistência à<br>compressão<br>(MPa) |
| 285                         | Silva <i>et al.</i> | 2021 | 302.84                          | 0.00                            | 205.00                       | 0.00                            | 1066.93                                    | 833.98                                    | 28.00           | 28.00                                |
| 286                         | Silva <i>et al.</i> | 2021 | 302.84                          | 0.00                            | 205.00                       | 0.00                            | 1066.93                                    | 833.98                                    | 7.00            | 25.00                                |
| 287                         | Silva <i>et al.</i> | 2021 | 311.22                          | 0.00                            | 224.77                       | 0.00                            | 1037.40                                    | 691.60                                    | 28.00           | 25.00                                |
| 288                         | Silva <i>et al.</i> | 2021 | 311.22                          | 0.00                            | 224.77                       | 0.00                            | 1037.40                                    | 691.60                                    | 7.00            | 16.00                                |
| 289                         | Silva <i>et al.</i> | 2019 | 316.47                          | 0.00                            | 203.95                       | 0.00                            | 1033.79                                    | 773.59                                    | 28.00           | 31.54                                |
| 290                         | Silva <i>et al.</i> | 2019 | 316.47                          | 0.00                            | 203.95                       | 0.00                            | 1033.79                                    | 773.59                                    | 7.00            | 28.63                                |
| 291                         | Silva <i>et al.</i> | 2019 | 328.00                          | 0.00                            | 260.00                       | 4.00                            | 1000.00                                    | 740.00                                    | 28.00           | 33.70                                |
| 292                         | Silva <i>et al.</i> | 2019 | 328.00                          | 0.00                            | 260.00                       | 4.00                            | 1000.00                                    | 740.00                                    | 7.00            | 21.70                                |
| 293                         | Silva <i>et al.</i> | 2019 | 366.66                          | 0.00                            | 200.00                       | 0.00                            | 1035.55                                    | 435.55                                    | 28.00           | 40.35                                |
| 294                         | Silva <i>et al.</i> | 2019 | 458.34                          | 0.00                            | 200.00                       | 0.00                            | 1033.34                                    | 700.01                                    | 28.00           | 42.41                                |
| 295                         | Silveira            | 1996 | 272.34                          | 0.00                            | 167.59                       | 0.00                            | 1304.42                                    | 706.68                                    | 28.00           | 33.64                                |
| 296                         | Silveira            | 1996 | 332.77                          | 0.00                            | 174.06                       | 0.00                            | 1303.77                                    | 641.64                                    | 28.00           | 35.79                                |
| 297                         | Silveira            | 1996 | 427.64                          | 0.00                            | 184.21                       | 0.00                            | 1298.26                                    | 543.86                                    | 28.00           | 51.68                                |
| 298                         | Siqueira            | 2020 | 331.29                          | 0.00                            | 231.90                       | 1.33                            | 824.91                                     | 927.24                                    | 28.00           | 32.00                                |
| 299                         | Siqueira            | 2020 | 331.29                          | 0.00                            | 231.90                       | 1.33                            | 824.91                                     | 927.24                                    | 7.00            | 26.00                                |
| 300                         | Siqueira            | 2020 | 403.43                          | 0.00                            | 206.20                       | 2.24                            | 824.78                                     | 926.98                                    | 28.00           | 37.50                                |
| 301                         | Siqueira            | 2020 | 403.43                          | 0.00                            | 206.20                       | 2.24                            | 824.78                                     | 926.98                                    | 7.00            | 32.00                                |
| 302                         | Siqueira            | 2020 | 425.21                          | 0.00                            | 198.43                       | 2.55                            | 807.89                                     | 926.95                                    | 28.00           | 34.00                                |
| 303                         | Siqueira            | 2020 | 425.21                          | 0.00                            | 198.43                       | 2.55                            | 807.89                                     | 926.95                                    | 7.00            | 30.00                                |
| 304                         | Siqueira e Hentges  | 2020 | 432.45                          | 0.00                            | 175.00                       | 2.78                            | 1158.30                                    | 675.22                                    | 28.00           | 56.70                                |
| 305                         | Siqueira e Hentges  | 2020 | 432.45                          | 0.00                            | 175.00                       | 2.78                            | 1158.30                                    | 675.22                                    | 7.00            | 53.50                                |
| 306                         | Siqueira; Hentges   | 2020 | 502.20                          | 0.00                            | 150.00                       | 4.10                            | 1196.91                                    | 641.46                                    | 28.00           | 84.90                                |

| Dados de Entrada Utilizados |                           |      |                              |                              |                           |                              |                                      |                                     |              |                                |
|-----------------------------|---------------------------|------|------------------------------|------------------------------|---------------------------|------------------------------|--------------------------------------|-------------------------------------|--------------|--------------------------------|
|                             | Autor                     | Ano  | Cimento (kg/m <sup>3</sup> ) | Escória (kg/m <sup>3</sup> ) | Água (kg/m <sup>3</sup> ) | Aditivo (kg/m <sup>3</sup> ) | Agregado graúdo (kg/m <sup>3</sup> ) | Agregado miúdo (kg/m <sup>3</sup> ) | Idade (dias) | Resistência à compressão (MPa) |
| 307                         | Siqueira; Hentges         | 2020 | 502.20                       | 0.00                         | 150.00                    | 4.10                         | 1196.91                              | 641.46                              | 7.00         | 71.70                          |
| 308                         | Slemer <i>et al.</i>      | 2018 | 282.96                       | 0.00                         | 116.33                    | 0.00                         | 1072.10                              | 924.34                              | 28.00        | 53.00                          |
| 309                         | Slemer <i>et al.</i>      | 2018 | 282.96                       | 0.00                         | 116.33                    | 0.00                         | 1072.10                              | 924.34                              | 7.00         | 45.00                          |
| 310                         | Sogayar <i>et al.</i>     | 2021 | 387.00                       | 0.00                         | 279.50                    | 0.00                         | 860.00                               | 645.00                              | 28.00        | 19.90                          |
| 311                         | Sogayar <i>et al.</i>     | 2021 | 387.00                       | 0.00                         | 279.50                    | 0.00                         | 860.00                               | 645.00                              | 7.00         | 18.50                          |
| 312                         | Teixeira <i>et al.</i>    | 2018 | 306.51                       | 0.00                         | 204.34                    | 0.00                         | 1117.07                              | 817.37                              | 28.00        | 29.92                          |
| 313                         | Teixeira <i>et al.</i>    | 2018 | 306.51                       | 0.00                         | 204.34                    | 0.00                         | 1117.07                              | 817.37                              | 7.00         | 22.40                          |
| 314                         | Toffoli e Bellei          | 2020 | 333.90                       | 0.00                         | 200.34                    | 0.00                         | 923.79                               | 857.01                              | 28.00        | 42.83                          |
| 315                         | Vasconcelos <i>et al.</i> | 2018 | 319.80                       | 0.00                         | 168.00                    | 3.15                         | 1176.00                              | 858.00                              | 28.00        | 20.30                          |
| 316                         | Vasconcelos <i>et al.</i> | 2018 | 319.80                       | 0.00                         | 168.00                    | 3.15                         | 1176.00                              | 858.00                              | 7.00         | 18.80                          |
| 317                         | Vasconcelos <i>et al.</i> | 2019 | 429.58                       | 0.00                         | 244.73                    | 0.00                         | 1473.58                              | 900.81                              | 28.00        | 14.60                          |
| 318                         | Vasconcelos <i>et al.</i> | 2019 | 429.58                       | 0.00                         | 244.73                    | 0.00                         | 1473.58                              | 900.81                              | 7.00         | 14.00                          |
| 319                         | Widmar <i>et al.</i>      | 2018 | 364.50                       | 0.00                         | 202.50                    | 0.00                         | 1338.00                              | 982.00                              | 28.00        | 54.30                          |
| 320                         | Widmar <i>et al.</i>      | 2018 | 364.50                       | 0.00                         | 202.50                    | 0.00                         | 1338.00                              | 982.00                              | 7.00         | 42.80                          |
| 321                         | Widmar <i>et al.</i>      | 2018 | 451.80                       | 0.00                         | 200.80                    | 0.00                         | 1102.00                              | 692.00                              | 28.00        | 62.80                          |
| 322                         | Widmar <i>et al.</i>      | 2018 | 451.80                       | 0.00                         | 200.80                    | 0.00                         | 1102.00                              | 692.00                              | 7.00         | 51.15                          |
| 323                         | Xavier <i>et al.</i>      | 2018 | 333.00                       | 0.00                         | 200.00                    | 4.44                         | 785.00                               | 1042.00                             | 28.00        | 45.40                          |
| 324                         | Zaleski <i>et al.</i>     | 2019 | 278.37                       | 0.00                         | 154.65                    | 3.09                         | 1082.55                              | 773.25                              | 28.00        | 45.19                          |