



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
ENGENHARIA CIVIL

IGOR LIRA PASSOS

**APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINAS PARA
PREVISÃO DE ABATIMENTO DE TRONCO DE CONE E RESISTÊNCIA À
COMPRESSÃO DE CONCRETOS CONVENCIONAIS**

FORTALEZA

2022

IGOR LIRA PASSOS

**APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINAS PARA
PREVISÃO DE ABATIMENTO DE TRONCO DE CONE E RESISTÊNCIA À
COMPRESSÃO DE CONCRETOS CONVENCIONAIS**

Monografia apresentada ao Curso de Engenharia Civil, do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial para a obtenção do título de bacharel em Engenharia Civil.

Prof. Orientador: LUCAS FEITOSA DE ALBUQUERQUE LIMA BABADOPULOS

FORTALEZA
Julho/2022

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

- P321a Passos, Igor Lira.
Aplicação de algoritmos de aprendizagem de máquinas para previsão de abatimento de tronco de cone e resistência à compressão de concretos convencionais / Igor Lira Passos. – 2022.
101 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Civil, Fortaleza, 2022.
Orientação: Prof. Dr. Lucas Feitosa de Albuquerque Limas Babadopulos.
1. Concreto convencional. 2. Resistência à compressão. 3. Abatimento de tronco de cone. 4. Modelos de aprendizado de máquina. 5. Análise de sensibilidade. I. Título.

CDD 620

IGOR LIRA PASSOS

**APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINAS PARA
PREVISÃO DE ABATIMENTO DE TRONCO DE CONE E RESISTÊNCIA À
COMPRESSÃO DE CONCRETOS CONVENCIONAIS**

Monografia apresentada ao Curso de Engenharia Civil, do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial para a obtenção do título de bacharel em Engenharia Civil.

Orientador: Prof. Lucas Feitosa de Albuquerque Limas Babadopulos, Ph.D.

Aprovada em: 15/07/2022

BANCA EXAMINADORA

Prof. Lucas Feitosa de A. Lima Babadopulos, Ph.D. (Orientador)
Universidade Federal do Ceará (UFC)

Prof. João Paulo Pordeus Gomes, Ph.D. (Examinador)
Universidade Federal do Ceará (UFC)

Prof. Antônio Eduardo Bezerra Cabral, Ph.D. (Examinador)
Universidade Federal do Ceará (UFC)

Aprenda como se você fosse viver para sempre. Viva como se você fosse morrer amanhã.

AGRADECIMENTOS

Aos meus pais, Vera e Edvano, pelo apoio e amor recebido.

À minha avó Irene, por me incentivar e acreditar no meu potencial, eu te dedico esta conquista.

Em especial, aos meus amigos da Kombi, Jonatas, Letícia, Luciana, Victor, Ivan e Lívia, por tornarem os dias na universidade mais leves e felizes, e por estarem presentes em cada passo desta longa jornada.

À UFC, pelo programa de Duplo Diploma, à *Campus France* e à *Centrale Nantes*, que me proporcionaram a enriquecedora e grandiosa experiência de um intercâmbio na França.

Aos meus queridos amigos, Leo, João, Lucas e Fernanda, pelas aventuras internacionais, por nossa incrível *coloc* e tantos momentos inesquecíveis.

Ao meu amigo laureado Jonatas, que sempre me incentivou a perseguir a oportunidade de intercâmbio. Eu sou teu fã!

Ao Victor, pois compartilhamos tantas risadas e reflexões, assim como momentos delicados da pandemia. Dêmos o nosso melhor na nossa pior fase. Sou muito grato!

Aos meus amigos, Allyson, Everton, Luciany, Matheus, Tereza, Felipe e Mariana. Obrigado pela amizade durante todos esses anos!

Aos professores Marco e Evandro, por me orientarem em suas pesquisas de iniciação científica, o que contribuiu enormemente para minha formação acadêmica.

Ao meu orientador Lucas, por ser exemplo de dedicação, pelo seu engajamento com o ReoM que inspira muitos, e que tanto contribuiu na produção deste projeto. Obrigado pela oportunidade!

RESUMO

Os algoritmos de aprendizado de máquinas é um assunto em destaque na tecnologia do concreto, uma vez que apresentam excelentes resultados na previsão de propriedades do concreto. Sob este prisma, o presente trabalho visa aplicar esses algoritmos na previsão de resistência à compressão e abatimento de tronco de cone de concretos convencionais. Três métodos de aprendizado de máquinas são desenvolvidos – Rede Neural Artificial (RNA), Floresta Aleatória (FA) e Máquina de Vetores de Suporte (SVM) – para classificação e regressão dos dados. Os modelos são avaliados por métricas estatísticas – Raiz Quadrada do Erro Médio, Erro Médio Absoluto, Acurácia, Precisão, *Recall*, e *F1-score* – usando técnicas de validação cruzada na otimização de hiperparâmetros e treino dos modelos. Cerca de 2750 dosagens de concreto são coletadas de artigos publicados na literatura, a partir dos quais foram criadas duas bases de dados. As variáveis de entrada dos modelos consistem no consumo dos materiais envolvidos, seja cimento, água, agregado miúdo, agregado graúdo, cinza volante, escória e plastificante. Em linhas gerais, os modelos apresentaram desempenho semelhante em todos os casos. A RNA performou melhor nas regressões para previsão de resistência ($R^2 = 0,692$) e abatimento ($R^2 = 0,796$). A RNA obteve a melhor acurácia de 52% para prever a classe de resistência, e a SVM apresentou a melhor acurácia de 76% na previsão da classe de abatimento. Os modelos com melhor desempenho foram interpretados por meio de análise de sensibilidade, investigando como a mudança no consumo de cada material influenciava na saída dos modelos, e os padrões de dosagem encontrados estavam de acordo com a literatura. Dessa forma, as ferramentas desenvolvidas neste trabalho são validadas, por apresentarem boa performance e interpretabilidade condizente com a literatura, e podem ser empregadas em um processo de dosagem, para determinar um traço inicial que atenda requisitos de resistência e abatimento.

Palavras chaves: Concreto convencional. Resistência à compressão. Abatimento de tronco de cone. Modelos de aprendizado de máquina. Análise de sensibilidade.

ABSTRACT

Over the last decades, machine learning techniques have been an important subject in concrete research since they achieve an excellent performance in predicting concrete properties. In this regard, this study concentrates on the use of machine learning methods to forecast the Compressive Strength (CS) and slump of conventional concrete. Three distinct ensemble machine learning techniques were used – Artificial Neural Network (ANN), Random Forest (RF) and Support Vector Machine (SVM) – for regression and classification. These methods were evaluated with statistical metrics – Root Mean Squared Error, Mean Absolute Error, Accuracy, Precision, Recall and F1-score – using cross validation technique for hyperparameters tuning and model training. More than 2750 concrete mix proportions were collected from previously published research papers and compiled in two datasets. The inputs are the components contents of concrete, including cement, water, fine aggregate, coarse aggregate, fly ash, slag and plasticizer. In general, the models showed a similar performance in all simulations. ANN performed better in regressions to predict CS ($R^2 = 0.796$) and slump ($R^2 = 0.692$). Moreover, ANN achieved the best accuracy of 52% to predict the class of CS, and the SVM obtained the best accuracy of 76% in to predict the slump class. The variation in CS and slump were achieved by varying the components contents in a sensitivity analysis. The effect of each component content in the concrete properties was investigated by evaluating the models, and the observed patterns of dosage were in accordance with those described in the literature. Therefore, the proposed models, by a high agreement with scientific studies and good performance, could be used as efficient tools to determine mix proportions that meet requirements of CS and slump.

Key words: Conventional concrete. Compressive strength. Slump. Machine learning; Sensitivity analysis.

LISTA DE FIGURAS

Figura 1 – Influência da relação a/c sobre resistência à compressão com concretos com adensamento insuficiente.....	23
Figura 2 – Influência da relação agregado/cimento sobre a resistência	24
Figura 3 – Influência do teor de agregados sobre a resistência à compressão	25
Figura 4 - Relação entre resistência à compressão e a idade para concretos produzidos com vários agregados	26
Figura 5 – Influência da dimensão máxima do agregado sobre a resistência à compressão	26
Figura 6 - Influência de cinzas volantes na resistência do concreto.....	27
Figura 7 - Influência de plastificantes na resistência do concreto.....	28
Figura 8 - Ensaio de abatimento de tronco de cone.....	29
Figura 9 – Principais fatores que influenciam a trabalhabilidade do concreto fresco....	30
Figura 10 – Efeito do uso de superplastificantes na consistência do concreto.....	32
Figura 11 – Representação esquemática do modelo matemático de um <i>perceptron</i> e da Multicamada de <i>perceptrons</i>	34
Figura 12 – Estudo paramétrico do efeito da sílica ativa para diferentes quantidades de cinzas volantes na predição da resistência do concreto.....	36
Figura 13 – Exemplo de Árvore de Decisão	37
Figura 14 – Representação esquemática do modelo matemático de um <i>perceptron</i> e da Multicamada de <i>perceptrons</i>	38
Figura 15 – Hiper planos de classificação	39
Figura 16 – Parâmetro de regularização no modelo SVM	40
Figura 17 – Fluxograma da metodologia para desenvolvimento dos modelos	41
Figura 18 – Matriz de confusão	46
Figura 19 – <i>Boxplots</i> com dados de consumo de cimento, água e agregados do banco de dados de resistência	53
Figura 20 – Consumo de água e cimento para concretos de alta e normal resistências .	55
Figura 21 – Análise descritiva do consumo de adições cimentícias nos concretos analisados do banco de dados de resistência	56
Figura 22 – Relação entre materiais cimentícios suplementares e a resistência	56
Figura 23 – Relações de água e plastificante com o ligante (cimento, cinza volante e escória) no banco de dados de resistência	57

Figura 24 – Histograma de frequência absoluta da resistência à compressão.....	58
Figura 25 – <i>Pairplot</i> entre cimento, água, agregados e a resistência à compressão.....	59
Figura 26 – <i>heatmap</i> das correlações entre o consumo de materiais, idade e resistência à compressão	60
Figura 27 – <i>Boxplots</i> com dados de consumo de cimento, água e agregados no banco de dados de abatimento	62
Figura 28 – Histograma e retas de regressão utilizados na análise descritiva do consumo de adições cimentícias (cinzas volantes e escórias) no banco de dados de abatimento .	62
Figura 29 – Relação entre materiais cimentícios e ligante (cimento, cinza volantes e escória) no banco de dados de abatimento	63
Figura 30 – Consumo de plastificante e de adições (cinzas volantes e escórias) no banco de dados de abatimento.....	64
Figura 31 – Histograma de densidade do abatimento	65
Figura 32 – <i>Heatmap</i> das correlações entre o consumo de materiais e abatimento	65
Figura 33 – Matrizes de confusão com resultados de previsão da classe de resistência: a) matriz de confusão clássica; b) matriz de confusão com os valores normalizados por linha.	68
Figura 34 – Matriz de confusão com resultados de previsão da classe de resistência para o modelo tolerante	69
Figura 35 – Matriz de confusão com resultados de previsão da classe de resistência para com a técnica de classificação ordinal.....	69
Figura 36 – Gráfico com valores previstos pelo modelo de regressão comparados aos valores reais de resistência	73
Figura 37 – Gráficos de PDP e ICE para cada variável de entrada do modelo de previsão de resistência.....	74
Figura 38 – Gráfico PDP entre resistência e consumos de cimento e água.....	75
Figura 39 – Gráfico PDP entre resistência e consumos de plastificante e água	76
Figura 40 – Relação entre resistência e o consumo de cimento para diferentes fatores a/c , considerando a compensação de volume nas substituições.....	76
Figura 41 – Relação entre a resistência e o fator a/c para diferentes consumos de cimento, considerando a compensação de volume nas substituições.....	77
Figura 42 – Relação entre a resistência e o consumo de cinza volante para diferentes consumos de ligante, considerando a substituição do cimento por cinza volante.....	78

Figura 43 – Relação entre a resistência e o consumo de escória para diferentes consumos de ligante, considerando a substituição do cimento por escória.....	79
Figura 44 – Relação entre a resistência e o consumo de agregado miúdo para diferentes consumos de cimento, considerando a compensação de volume nas substituições	79
Figura 45 – Relação entre a resistência e o consumo de agregado graúdo para diferentes consumos de cimento, considerando a compensação de volume nas substituições	80
Figura 46 – Relação entre a resistência e o consumo de agregado graúdo para diferentes consumos de agregado miúdo	81
Figura 47 – Matriz de confusão com resultados de previsão da classe de abatimento...	82
Figura 48 – Matriz de confusão com resultados de previsão da classe de abatimento usando a técnica de subamostragem.....	83
Figura 49 – Matriz de confusão com resultados de previsão da classe de abatimento usando técnica de classificação ordinal	83
Figura 50 – Gráfico com valores previstos pelo modelo de regressão	88
Figura 51 – Gráficos PDP e ICE para cada variável de entrada do modelo de previsão de abatimento	89
Figura 52 – Gráfico PDP entre abatimento e consumos de água e cimento.....	90
Figura 53 – Gráfico PDP entre abatimento e consumos de água e plastificante	91
Figura 54 – Relação entre abatimento e consumo de materiais secos para diferentes consumos de água, considerando a compensação de volume nas substituições.	91
Figura 55 – Relação entre abatimento e consumo de plastificante para diferentes consumos de cimento, considerando a compensação de volume na substituição.	92
Figura 56 – Relação entre o abatimento e o consumo de cinza volante para diferentes consumos de ligante, considerando a substituição de cimento por cinza volante.....	93
Figura 57 – Relação entre abatimento e consumo de agregado miúdo para diferentes consumos de cimento, considerando a compensação de volume na substituição	94
Figura 58 – Relação entre abatimento e consumo de agregado graúdo para diferentes consumos de cimento, considerando a compensação de volume na substituição.	94
Figura 59 – Relação entre o abatimento e o consumo de escória para diferentes consumos de ligante, considerando a substituição de cimento por escória.	95

LISTA DE TABELAS

Tabela 1 – Classes de resistência do Grupo I	19
Tabela 2 – Classes de consistência do concreto fresco e aplicações correspondentes ...	19
Tabela 3 – Parâmetros de dosagem em função da trabalhabilidade e resistência.....	22
Tabela 4 - Identificação dos bancos de dados.....	42
Tabela 5- Valores de hiperparâmetros avaliados para cada modelo	45
Tabela 6- Consumo padrão e densidade relativa para cada material	49
Tabela 7- Banco de dados final para previsão de resistência à compressão.....	53
Tabela 8 – Banco de dados para previsão de abatimento de tronco de cone.....	61
Tabela 9- Comparativo entre os modelos de classificação para previsão de resistência	67
Tabela 10- Classes de resistência para intervalos de consumo de cimento	70
Tabela 11- Classes de resistência para intervalos de fatores a/c.....	70
Tabela 12- Classes de resistência para intervalos de consumo de agregado graúdo	71
Tabela 13- Classes de resistência para intervalos de consumo de agregado miúdo	71
Tabela 14- Comparativo entre modelos de regressão para previsão de resistência.....	72
Tabela 15- Comparativo entre modelos de classificação para previsão de abatimento..	81
Tabela 16- Classes de abatimento para intervalos de consumo de água	84
Tabela 17- Consumo de água aproximado para diferentes intervalos de abatimento pelo método ABCP/ACI.....	84
Tabela 18- Classes de abatimento para intervalos de consumo de plastificante.....	85
Tabela 19- Classes de abatimento para intervalos de consumo de cimento	85
Tabela 20- Classes de abatimento para intervalos de consumo de agregado miúdo	85
Tabela 21- Classes de abatimento para intervalos de consumo de agregado graúdo	86
Tabela 22- Comparativo entre modelos de regressão para previsão de abatimento	87

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Justificativa.....	16
1.2	Objetivos geral e específicos.....	16
1.3	Organização do texto	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	Concreto.....	18
2.2	Materiais constituintes do concreto.....	20
2.2.1	Cimento	20
2.2.2	Água	20
2.2.3	Agregados	21
2.2.4	Adições.....	21
2.2.5	Aditivos.....	21
2.3	Parâmetros da dosagem	22
2.3.1	Resistência à Compressão	23
2.3.2	Trabalhabilidade.....	28
2.4	Modelos de predição	32
2.4.1	Rede Neural Artificial	33
2.4.2	Árvore de Decisão	36
2.4.3	Máquina de Vetores de Suporte	38
3	METODOLOGIA.....	41
3.1.1	Pesquisa Bibliográfica	41
3.1.2	Descrição do Banco de Dados.....	42
3.1.3	Análise dos Dados	44
3.1.4	Divisão dos Dados	44
3.1.5	Ajuste de Hiperparâmetros	45
3.1.6	Comparação dos Modelos	45
3.1.7	Critério de Escolha dos Modelos.....	48
3.1.8	Validação dos Modelos	48
4	ANÁLISE EXPLORATÓRIA	53
4.1	Banco de dados para previsão de resistência.....	53
4.2	Banco de dados para previsão de abatimento	61
5	MODELAGEM PREDITIVA DOS DADOS.....	67
5.1	Modelo de classificação para previsão de resistência	67
5.1.1	Interpretação do modelo	70

5.2	Modelo de Regressão Para Previsão de Resistência	72
5.2.1	Interpretação do Modelo.....	73
5.3	Modelo de classificação para previsão de abatimento.....	81
5.3.1	Interpretação do Modelo.....	84
5.4	Modelo de Regressão Para Previsão de Abatimento.....	87
5.4.1	Interpretação do Modelo.....	88
6	CONCLUSÕES E SUGESTÕES	96
	REFERÊNCIAS	99

1 INTRODUÇÃO

O concreto é um dos materiais de construção mais utilizados no mundo, o que é explicado por diversos fatores, tais quais: disponibilidade e valor econômico dos materiais constituintes; versatilidade e adaptabilidade, podendo ser empregado em inúmeras aplicações, como prédios, pontes e outros; e requisitos mínimos de manutenção quando em serviço. É tipicamente uma mistura de cimento, agregados graúdos e miúdos, e água, podendo conter ainda eventuais adições e aditivos que contribuem para um melhor desempenho, particularmente capaz de resistir, em estruturas, aos esforços de compressão (MINDESS; YOUNG; DARWIN, 2003).

A dosagem do concreto é o processo em que se determinam os ingredientes adequados e necessários na composição, assim como suas proporções. O principal objetivo da dosagem é atingir propriedades desejáveis nos estados fresco e endurecido, tais como trabalhabilidade, resistência e durabilidade (TUTIKIAN; HELENE, 2011).

Alguns métodos tradicionais de dosagem são ou foram amplamente usados no Brasil, como o método IBRACON (TUTIKIAN; HELENE, 2011), o método a ABCP/ACI (desenvolvido pelo *American Concrete Institute*), o método INT (desenvolvido no Instituto Nacional de Tecnologia do Rio de Janeiro), o método ITERS (desenvolvido no Instituto Tecnológico do Estado do Rio Grande do Sul), dentre outros.

Nas últimas décadas, foram desenvolvidos na literatura diversos modelos que empregam algoritmos de aprendizagem de máquina para predição de propriedades do concreto (CHITHRA *et al.*, 2016; NADERPOUR; RAFIEAN; FAKHARIAN, 2018; TOPÇU; SARIDEMIR, 2008). Estes algoritmos se adaptam bem a problemas com muitas variáveis de estudo, captando relações não lineares entre as mesmas que os modelos tradicionais não exploram bem. Provou-se que esses algoritmos podem apresentar ótimos resultados em diversas aplicações envolvendo concretos convencionais, Concreto de Alto Desempenho (CAD) e Concreto de Ultra Alto Desempenho (CUAD), concretos leves e pesados. Nesses estudos, as categorias de algoritmos mais exploradas foram as redes neurais, as árvores de decisão, as máquinas de vetores de suporte e os algoritmos genéticos (BEN CHAABENE; FLAH; NEHDI, 2020).

Algo que pode ser mencionado como uma desvantagem dos modelos de aprendizado de máquina é que eles são difíceis de serem interpretados, pois as funções de decisão usadas internamente para regressão e classificação dos dados são complexas e não possuem coeficientes de correlação explícitos. Para contornar essa desvantagem, a

interpretação pode ser feita por análise de sensibilidade, estudando a perturbação introduzida no modelo ao mudar cada variável de entrada, mantendo as restantes constantes (CORTEZ; EMBRECHTS, 2013).

Sendo assim, este trabalho buscou a aplicação de diferentes modelos de aprendizado de máquina para a modelagem de dados referentes ao estado fresco (abatimento de tronco de cone) e ao estado endurecido (resistência à compressão simples) de concretos convencionais. Devido à necessidade de volumes de dados os maiores possíveis, o trabalho buscou dados secundários, de fontes publicadas.

1.1 Justificativa

A resistência à compressão e a consistência são propriedades importantes para determinar se um concreto está apto para determinada aplicação, o que é indicado pelas classes de resistência e de consistência apresentadas na ABNT NBR 8953:2015. Prever tais propriedades a partir do consumo de cada material é uma ferramenta útil na construção civil, pois tem o potencial de acelerar o processo de dosagem e tomadas de decisão de ajustes de traço em laboratório e em obras de construção civil, diminuindo os custos e o desperdício dos materiais envolvidos.

Os estudos que desenvolvem técnicas preditivas na tecnologia do concreto tratam usualmente de Redes Neurais Artificiais (RNAs) para predição de resistência à compressão de concretos especiais, como os mais de 20 estudos mencionados na revisão literária de BEN CHAABENE, FLAH e NEHDI (2020). O presente trabalho procura empregar outros modelos de previsão, não somente da resistência, mas também do abatimento de tronco de cone, considerando dados de concretos convencionais. Além disso, outra contribuição deste trabalho é a criação de bancos de dados com dosagens de concretos convencionais com resultados de resistência e abatimento, pois o acesso a bancos de dados como estes é escasso na literatura.

1.2 Objetivos geral e específicos

O presente trabalho tem como objetivo geral investigar o uso de diferentes algoritmos de aprendizado de máquina para predição do abatimento de tronco de cone do concreto fresco e a resistência à compressão do concreto endurecido em diferentes idades. Para isso, serão perseguidos os seguintes objetivos específicos:

- a) Criar bancos de dados contendo dosagens de concreto e resultados do ensaio de resistência à compressão e abatimento de tronco de cone;

- b) Desenvolver modelos de aprendizado de máquina para classificação e regressão a partir dos bancos de dados criados e investigar os que melhor se adequam à previsão das propriedades dos concretos convencionais;

1.3 Organização do texto

Este primeiro capítulo introduziu o trabalho, sublinhando sua justificativa e objetivos. O restante do texto será organizado da seguinte forma:

No Capítulo 2, apresentam-se as classificações e materiais constituintes do concreto, e os parâmetros de dosagem que influenciam na trabalhabilidade e resistência do concreto, com descrições construídas a partir da literatura especializada. Em seguida, discute-se sobre os modelos de aprendizado de máquina mais usuais na tecnologia do concreto.

No Capítulo 3, expõe-se a metodologia aplicada no presente trabalho para criação dos bancos de dados, e para o desenvolvimento dos modelos preditivos.

No Capítulo 4, mostra-se a análise exploratória para cada um dos dois bancos de dados com os concretos avaliados a partir da literatura, sendo um para abatimento de tronco de cone e outro para resistência à compressão.

No Capítulo 5, apresentam-se os resultados das predições e a comparação de desempenho dos modelos. Em seguida, foram construídos casos de estudo com o intuito de interpretar cada modelo escolhido, a partir de variações de composição dos materiais, de maneira a explicitar efeitos de dosagem dos concretos no seu abatimento de tronco de cone e na sua resistência à compressão simples.

Por fim, no Capítulo 6, serão apresentadas as principais conclusões deste trabalho e algumas sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

2.1 Concreto

O Concreto de Cimento Portland (CCP) é o segundo material mais consumido do mundo em massa, com um consumo anual próximo à 30 bilhões de toneladas (MONTEIRO; MILLER; HORVATH, 2017). Devido a sua versatilidade no estado fresco, ao seu bom desempenho estrutural no estado endurecido, à disponibilidade dos materiais constituintes e à durabilidade, o CCP se tornou um material indispensável nas construções (SIDNEY; DAVID; J., 2003).

Segundo a ABNT NBR 12655:2015, o CCP é definido como um

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

A classificação do CCP é feita atentando-se ao peso específico no estado endurecido (leve, normal ou pesado), ao grupo de resistência à compressão (Grupo I ou II) e à classe de abatimento no estado fresco (S10 a S220). Espera-se que um concreto convencional tenha as seguintes classificações:

- a) peso normal: peso específico entre 2000 e 2800 kg/m³ (ABNT NBR 12655:2015);
- b) resistência normal: Grupo I para Resistência à Compressão, isto é, concretos com resistência inferior à 55 MPa (ABNT NBR 8953:2015);
- c) sem a propriedade de ser autoadensável: não pertencer à classe S220 de espalhamento (ABNT NBR 15823:2017).

As classes da ABNT NBR 8953:2015 para resistência à compressão e para a consistência são mostradas na Tabela 1 e Tabela 2. Essas classes norteiam tipos de aplicações do concreto em situações que requerem propriedades desejáveis para trabalhabilidade e resistência. Vale ressaltar que estas classes são usadas nos modelos de classificação desenvolvidos neste trabalho.

Tabela 1 – Classes de resistência do Grupo I

Classe de Resistência Grupo I	Resistência Característica à Compressão (MPa)
C20	20
C25	25
C30	30
C35	35
C40	40
C45	45
C50	50

Fonte: ABNT NBR 8953:2015

Tabela 2 – Classes de consistência do concreto fresco e aplicações correspondentes

Classe	Abatimento (mm)	Aplicações típicas
S10	10 < A < 50	Concreto extrusado; vibro prensado ou centrifugado
S50	50 < A < 100	Alguns tipos de pavimentos e de elementos de fundações
S100	100 < A < 160	Elementos estruturais com lançamento convencional do concreto
S160	160 < A < 220	Elementos estruturais com lançamento bombeado do concreto
S220	A > 220	Elementos estruturais esbeltos ou com alta densidade de armaduras

Fonte: ABNT NBR 8953:2015

Concreto de Alto Desempenho (CAD) é um termo usado para descrever concreto com propriedades especiais não atribuídas ao concreto normal. Alto desempenho significa que o concreto tem uma ou mais das seguintes propriedades: baixa retração, baixa permeabilidade, alto módulo de elasticidade ou alta resistência. De acordo com RUSSELL (1997), o Instituto Americano do Concreto (do inglês, *American Concrete Institute*) define um CAD como:

concreto que atende a requisitos especiais de desempenho e uniformidade que nem sempre podem ser alcançados rotineiramente usando apenas materiais convencionais e práticas normais de mistura, colocação e cura. Os requisitos podem envolver aprimoramentos de colocação e compactação sem segregação, propriedades mecânicas de longo prazo, resistência inicial, tenacidade, estabilidade de volume ou vida útil em ambientes severos.

Este trabalho visa compor bancos de dados de concretos convencionais e utiliza-los para construção de modelos de aprendizado de máquina. Visto que boa parte dos artigos com dados experimentais encontrados na literatura tratam de CAD, mas que a definição para essa terminologia pode variar entre os autores, adotou-se aqui uma simplificação: concretos com

resistência abaixo de 55 MPa são concretos convencionais, seguindo as classificações do Grupo I de resistência da ABNT NBR 8953:2015, mesmo que os autores os tratem como CAD.

2.2 Materiais constituintes do concreto

2.2.1 Cimento

O Cimento Portland é fabricado pela mistura homogênea de sulfato de cálcio (gesso) e clínquer. O clínquer é obtido pela sinterização de calcário e argila com eventuais correções de teores de óxidos de ferro, alumínio, com uso de minérios etc. Ele pode receber adições como escória de alto forno, cinza volantes, argilas calcinadas, e outras, com uso corrente no Brasil (ABCP, 2003).

De acordo com a ABNT NBR 16697:2018, O Cimento Portland Comum é denotado por CPI (ou CPI-S para adições de 5%). Contudo, 75% do cimento fabricado no Brasil são cimentos compostos, isto é, CII-E com adição de escória, CII-Z com adição de material pozolânico, ou CII-F com adição de Fíler (ABCP, 2003). Existem ainda o Cimento Portland de Alto Forno (CP III), Cimento Portland Pozolânico (CP IV), Cimento Portland de Alta Resistência Inicial (CP V-ARI), entre outros.

O cimento é um aglomerante hidráulico, pois em reação com a água torna-se pastoso e logo endurece, ganhando alta resistência, durabilidade, e conserva a sua estrutura mesmo após o contato com a água novamente. Assim, a mistura de cimento com água e agregados possibilita a produção de concretos (caso haja presença de agregados graúdos, de diâmetro máximo característico – DMC – acima de 4,75mm) e argamassas (sem a presença de agregados com DMC acima de 4,75mm) amplamente empregados na construção civil (ABCP, 2003).

2.2.2 Água

A água é o material essencial para hidratar o cimento, e produzir uma mistura com mais trabalhabilidade. A ABNT NBR 15900-1:2009 apresenta os requisitos para água usada na pasta, em geral potável e sem quantidades perceptíveis de constituintes inorgânicos ou substâncias orgânicas indesejáveis. Ela está presente em toda a vida útil do concreto, e influencia resistência, pega, exsudação, retração por secagem, entre outros fenômenos no concreto. O excesso de água impacta na resistência à compressão dos concretos devido à formação de vazios, além de comprometer a durabilidade e vida útil da estrutura (ABCP, 2003). A quantidade de água para hidratar totalmente os grãos de cimento é da ordem de 0,2 a 0,3 (em

termos de relação água/cimento), sendo o restante da água incluída na mistura por vezes necessária para garantir a trabalhabilidade e com a desvantagem de em seguida evaporar, produzindo vazios no concreto (NEVILLE, 2015).

2.2.3 Agregados

Os agregados ocupam cerca de 60 a 80% do volume do concreto, sendo fator determinante para a resistência, trabalhabilidade e custos. Agregados graúdos (normalmente brita, pedregulho ou pedra esmagada) são grãos que passam pela peneira com abertura de malha de 75 mm e ficam retidos na peneira com abertura de malha de 4,75 mm. Agregados miúdos (normalmente areias naturais e artificiais) são os grãos passantes da peneira com abertura de 4,75 mm e retidos na peneira com abertura de malha de 150 μ m (ABNT NBR 7211:2005). A qualidade da pasta de cimento é dependente das propriedades dos agregados, como a granulometria, módulo de finura, massa específica, massa unitária e dimensão máxima característica (PETRUCCI; PAULON, 1993).

2.2.4 Adições

Cinza volante e escória granulada de alto forno (ou brevemente, escória) são materiais cimentícios suplementares que, quando usados em conjunto com Cimento Portland, contribuem para melhorar as propriedades do concreto no estado fresco e endurecido devido à atividade hidráulica (caso da escória) ou pozolânica (KOSMATKA; PANARESE; KERKHOFF, 2002, p.58). As cinzas volantes são resíduos na forma de pó mineral resultado da combustão de carvão mineral e que possui atividade pozolânica, isto é, a capacidade de reagir com hidróxido de cálcio e formar compostos com propriedades cimentícias. (ABNT NBR 12653:2014). A escória é um subproduto do tratamento de minério de ferro em alto-forno, obtido sob forma granulada por resfriamento brusco (ABNT NBR 16697:2018). Outras adições que podem ser mencionadas são o metacaulim, a sílica ativa, entre outros, normalmente utilizados em concretos de alto desempenho.

2.2.5 Aditivos

Aditivos são produtos incorporados ao concreto além do cimento, materiais cimentício, água e agregados, normalmente incluídos como líquidos. Os aditivos são adicionados antes ou durante a mistura do concreto, e têm por objetivos: atingir certas propriedades do concreto; manter a qualidade do concreto durante a mistura, transporte,

lançamento e cura em situações adversas; e resolver problemas emergenciais durante a concretagem, reduzindo custos na construção. Os aditivos podem ser incorporadores de ar, redutores de água, superplastificantes, aceleradores e retardador de pega, dentre outros (ABNT NBR 11768-1:2019).

2.3 Parâmetros da dosagem

O estudo de dosagem é feito com o intuito de encontrar uma mistura ideal e econômica com os materiais disponíveis. Os pontos que podem nortear a dosagem são resistência mecânica, trabalhabilidade, durabilidade e deformabilidade (TUTIKIAN; HELENE, 2011).

A Tabela 3 aponta certos parâmetros que podem influenciar na resistência e na trabalhabilidade do concreto. Estas conclusões foram adaptadas de HELENE e TERZIAN (1993) a partir de constatações experimentais. Percebe-se que a quantidade de água e as características físicas dos agregados explicam as propriedades do concreto. Misturas com maior consumo de água tendem a apresentar maior fluidez e pior a resistência. A substituição de agregado graúdo por miúdo tende a aumentar a resistência, e diminuir a fluidez dos concretos. Contudo, existem vários casos em que estas constatações não são encontradas na prática, pois o processo de dosagem envolve diversos outros fatores, e que serão explorados neste trabalho tanto na continuidade desta revisão quanto nos resultados e discussões.

Tabela 3 – Parâmetros de dosagem em função da trabalhabilidade e resistência

Parâmetros de Dosagem	Para uma melhor trabalhabilidade do concreto fresco	Para uma melhor resistência do concreto endurecido
Granulometria do agregado miúdo	Preferencialmente fina	Preferencialmente grossa
Relação graúdo/miúdo	Diminuir	Aumentar
Consumo de água	Aumentar até um certo ponto	Diminuir
Granulometria total	Preferível contínua	Preferível descontínua
Dimensão máxima característica do agregado	Preferencialmente média	Preferencialmente pequena
Geometria do grão do agregado graúdo	Preferencialmente esférico (pedregulho)	Preferencialmente irregular (pedra britada)

Fonte: ASSUNÇÃO (2002)


2.3.1 Resistência à Compressão

MEHTA *et al.* (1994) comentam sobre a complexidade em prever a resistência do concreto. Esta depende de vários fatores, como a porosidade da matriz de cimento, porosidade da zona de transição entre cimento e agregado e porosidade dos agregados, além dos parâmetros do corpo de prova e carregamento do ensaio. HELENE e TERZIAN (1993) trazem uma perspectiva de quais parâmetros podem ser mais facilmente controlados na prática. Segundo os autores, para alterar a resistência à compressão, deve-se atuar sobre o grau de hidratação ou sobre a relação água/cimento (a/c). A mudança na relação a/c pode ser obtida por meio:

- a) mudança do tipo de cimento (finura ou composição química);
- b) mudança dos agregados (textura, dimensão, granulometria, absorção d'água);
- c) uso de aditivos redutores de água ou superplastificantes.

Quando o concreto está plenamente adensado, a sua resistência diminui com o aumento da relação a/c conforme relações conhecidas como “lei” de ABRAMS (1919). Contudo, caso o grau de adensamento do concreto seja insuficiente, observa-se um comportamento contrário para menores relações a/c , conforme apresentado na Figura 1. Neste caso, tanto a relação a/c quanto o grau de adensamento afetam a porosidade da matriz e da zona de transição.

Figura 1 – Influência da relação a/c sobre resistência à compressão com concretos com adensamento insuficiente



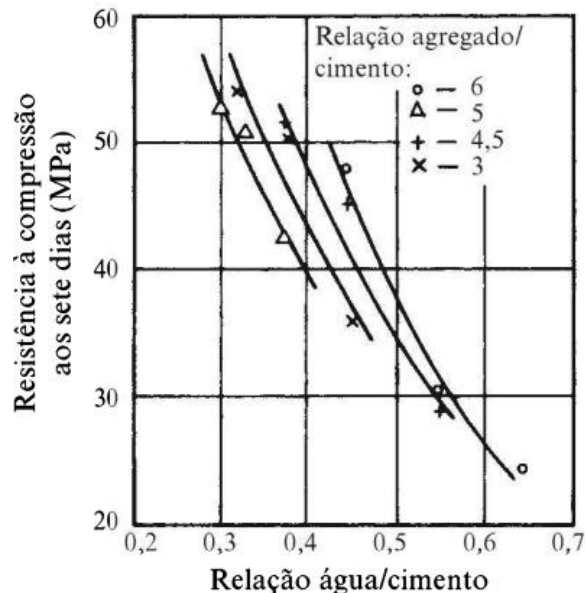
Fonte: NEVILLE (2015)

NEVILLE (2015) comenta que a relação a/c não é o único fator determinante para explicar a resistência de um concreto totalmente adensável. Considerando concretos que possuam características semelhantes de cimento e agregados, a resistência também pode ser influenciada por:

- relação entre quantidades de cimento e agregado
- granulometria, textura superficial, forma, resistência e rigidez das partículas de agregado
- dimensão máxima do agregado

Para uma mesma relação a/c , uma mistura com menor consumo de cimento pode gerar concretos com melhor resistência, pois a relação de agregado/cimento também é um fator secundário importante a ser considerado, conforme apresentado na Figura 2. NEVILLE (2015) explica que isso pode ocorrer devido à diminuição da quantidade de água total em misturas com mais agregados. Outra possível explicação é que um maior teor de agregados resulta em retração e exsudação menores, o que diminui danos à aderência entre pasta de cimento e os agregados.

Figura 2 – Influência da relação agregado/cimento sobre a resistência




Fonte: NEVILLE (2015)

Estudos mostram que quando o teor de agregados aumenta, entre 0 a 40% do volume total da mistura, ocorre uma queda na resistência, mas o efeito é o oposto quando o volume de agregados ocupa entre 40 e 80%, conforme apresentado na Figura 3. Neste caso, a

resistência aumenta com o aumento do teor de agregados (STOCK; HANNANTT; WILLIAMS, 1979).


Figura 3 – Influência do teor de agregados sobre a resistência à compressão



Fonte: STOCK *et al.* (1979)

NEVILLE (2015) indica que concretos com agregado graúdos de superfície mais rugosa alcançam maior resistência que aqueles com agregados de superfície lisa, e que a influência do tipo de agregado depende da relação a/c . Para valores de a/c abaixo de 0,40, o uso de agregado britado aumenta consideravelmente a resistência do concreto quando comparado com o uso de seixo. Contudo, com o aumento da relação a/c , a influência do agregado fica cada vez menos importante, pois a resistência da pasta de cimento hidratada torna-se o fator primordial. A Figura 4 mostra esse estudo sobre os agregados, e observa-se que para uma relação a/c e uma idade fixadas, a resistência pode variar bastante para diferentes tipos de agregado.

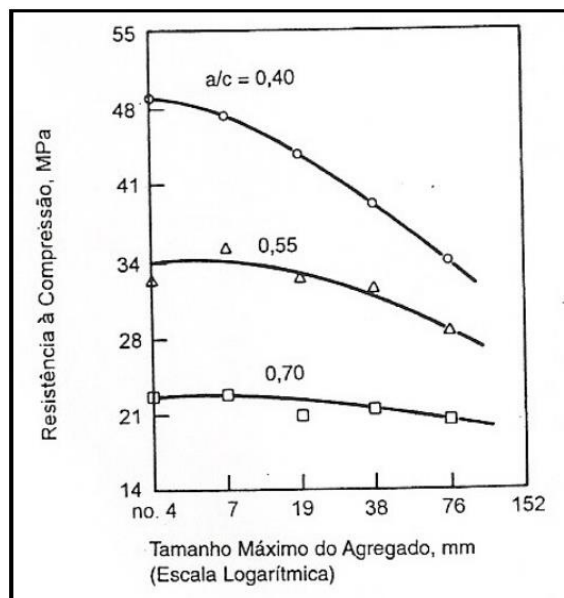
Figura 4 - Relação entre resistência à compressão e a idade para concretos produzidos com vários agregados



Fonte: NEVILLE (2015)

MEHTA *et al.* (1994) comentam sobre a dimensão máxima do agregado graúdo. Sublinha-se que o aumento da dimensão do agregado utilizado tende a produzir uma diminuição na resistência do concreto para relações a/c fixadas, conforme apresentado na Figura 5.

Figura 5 – Influência da dimensão máxima do agregado sobre a resistência à compressão




Fonte: MEHTA *et al.* (1994)

Com base na Figura 3, Figura 4 e Figura 5, e os comentários sobre os agregados, constata-se que não existe uma relação direta entre o consumo de agregados e a resistência, pois diversas características de tipo, formato, textura, granulometria, e dimensão máxima dos grãos influenciam na resistência.

KOSMATKA *et al.* (2002, p.64) investigam a influência da adição de escória e cinza volante sobre a resistência do concreto. Esses materiais contribuem para a resistência do concreto, mas em comparação com concretos constituídos unicamente com Cimento Portland, a resistência observada nem sempre é maior nas primeiras idades. Isso ocorre principalmente por conta da baixa velocidade das reações pozolânicas nos primeiros dias, e o tempo necessário para alcançar resistências usuais é maior.

A Figura 6 apresenta a evolução típica de resistência à compressão de concretos ao longo do tempo. Nela, a linha em vermelho representa o concreto sem adições, e as outras representam concretos diferentes tipos de cinza volante (CV1 a CV6). Observa-se que, nos primeiros dias, concretos com cinza volante têm usualmente menor resistência que o concreto de controle, mas conforme a idade aumenta, a resistência aumenta consideravelmente. Este comportamento é similar no concreto com adição de escória. Além disso, percebe-se que nem todos os concretos com adições apresentam melhor resistência que o concreto de controle ao final dos 100 dias, mostrando que a substituição do Cimento Portland algumas vezes pode gerar concretos menos resistentes.


Figura 6 - Influência de cinzas volantes na resistência do concreto



Fonte: adaptado de KOSMATKA *et al.* (2002, p.64)

Em se tratando do uso de aditivos, KOSMATKA *et al.* (2002, p.112) comparam concretos com e sem plastificante, sem alteração da relação água/cimento, e concluem que a resistência não varia muito, ficando sempre equiparável em todos os casos abordados. O concreto de controle, isto é, sem consumo de plastificante, é destacado em vermelho, e as dosagens com diferentes tipos de plastificantes são as restantes (FN, FM e FX), ver Figura 7.

Figura 7 - Influência de plastificantes na resistência do concreto



Fonte: adaptado de KOSMATKA *et al.* (2002, p.112).

A ABNT NBR 11768-1:2019 comenta sobre a possível incompatibilidade dos aditivos com os demais materiais constituintes, o que pode gerar perda de resistência.

2.3.2 *Trabalhabilidade*

A trabalhabilidade do concreto pode ser entendida pela facilidade de lançamento, consolidação e acabamento do concreto fresco e a habilidade de resistir à segregação. Assim, os materiais que constituem o concreto fresco devem se manter unidos durante o transporte e lançamento. Alguns fatores influenciam na trabalhabilidade do concreto são: método e a duração de transporte; características do material cimentício; classificação, forma e textura dos agregados; volume de ar incorporado; quantidade de água; temperatura do concreto e do ambiente; e adições (KOSMATKA; PANARESE; KERKHOFF, 2002, p.3).

As propriedades relacionadas à trabalhabilidade incluem a consistência/fluidez, a resistência à segregação, e a facilidade ao bombeamento. Dentre essas propriedades, a

consistência é a mais abordada na literatura consultada para concretos convencionais e trata da dificuldade que o concreto recém misturado oferece a ser deformado/fluir.

Uma forma comum de se mensurar uma propriedade de consistência relacionada à trabalhabilidade do concreto é através do ensaio de abatimento do tronco de cone, cujo procedimento é detalhado pela ABNT NBR NM 67:1998. A Figura 8a mostra o kit para realização do ensaio, a Figura 8b mostra a mensuração do abatimento, e na Figura 8c faz-se a mensuração da mesma amostra após acrescentar mais água na mistura. Neste ensaio, o concreto se abate sob ação do próprio peso a partir de uma geometria e um adensamento padrões.

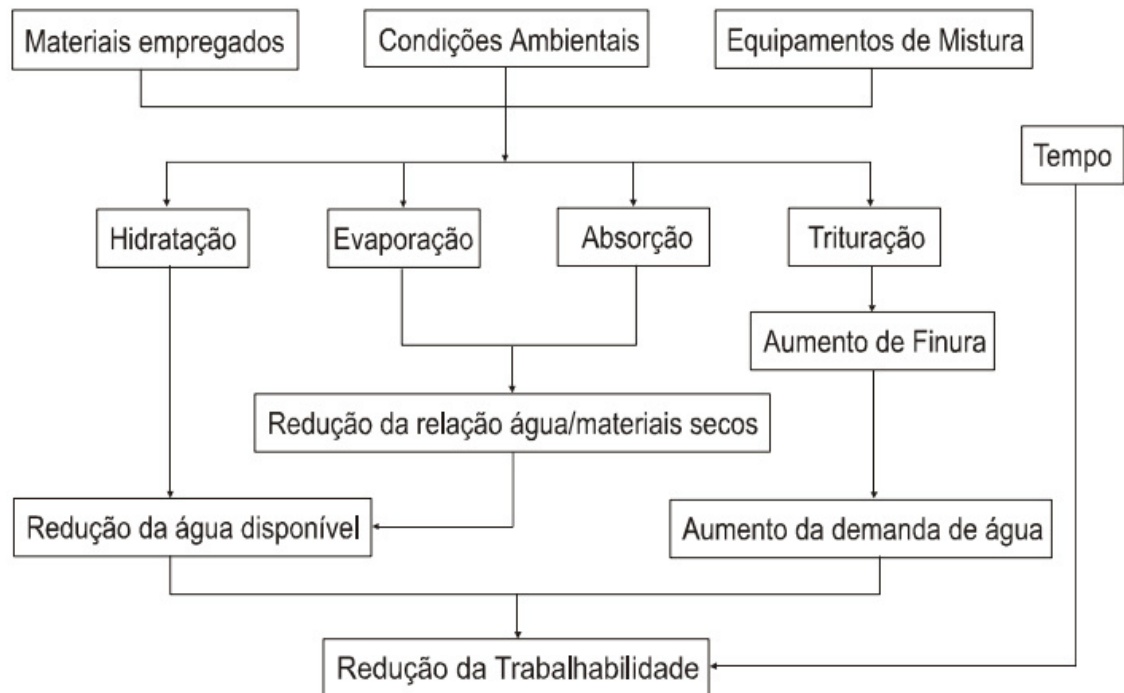
Figura 8 - Ensaio de abatimento de tronco de cone



Fonte: ALMEIDA *et al.* (2018)

A Figura 9 apresenta os principais fatores que podem influenciar a trabalhabilidade do concreto fresco. O aumento da finura dos materiais tende a demandar mais água para conseguir a mesma consistência, devido à maior demanda de água para recobrir materiais de maior superfície específica. Em outras palavras, o uso de materiais mais fino costuma produzir concretos com maior consistência (menor fluidez). No caso de concretos convencionais, costuma-se confundir isso com uma redução de trabalhabilidade, devido ao fato de comumente as aplicações de concretos convencionais serem mais facilitadas com menores consistências. Além disso, o aumento da quantidade de materiais secos, isto é, cimento e agregados, provoca a redução da água disponível para lubrificação da mistura e aumenta a consistência (GIAMMUSSO, 1992). Isso pode ser descrito por equações conhecidas como “lei” de LYSE (1932).

Figura 9 – Principais fatores que influenciam a trabalhabilidade do concreto fresco



Fonte: GIAMMUSSO (1992)

NEVILLE (2015) afirma que o principal fator que afeta a trabalhabilidade é o teor de água na mistura. Além disso, caso a água e a proporção dos outros materiais mantenha-se constante, a trabalhabilidade é afetada pela dimensão máxima do agregado, sua granulometria, forma e textura. O autor também conclui que quanto maior a relação a/c , mais fina deve ser a granulometria para aumentar a fluidez, e que existe uma relação entre agregado graúdo e miúdo ótima para uma relação a/c fixada. Em suma, deve-se atentar para a relação a/c , para as propriedades físicas dos agregados e para o teor de água em relação à mistura seca.

FABRO *et al.* (2011) concluem que a forma dos grãos dos agregados finos impacta fortemente a fluidez da argamassa, e para maiores coeficientes de forma (agregados mais cúbicos), obtém-se maior. Além disso, areias constituídas por partículas esféricas e arredondadas têm ângulos de atrito menores que as areais constituídas de partículas lamelares, o que favorece a fluidez. No referido estudo, observou-se que quanto maior o coeficiente de forma, maior o abatimento do tronco de cone.

SILVA e GEYER (2013) concluem que com maiores índices de irregularidade do agregado graúdo, maior será a necessidade de água para alcançar a mesma fluidez. Isso ocorre, pois as formas irregulares funcionam como barreiras dificultando a mobilidade da pasta de cimento, devido ao seu alto índice de área superficial característica da forma alongada-lamelar.

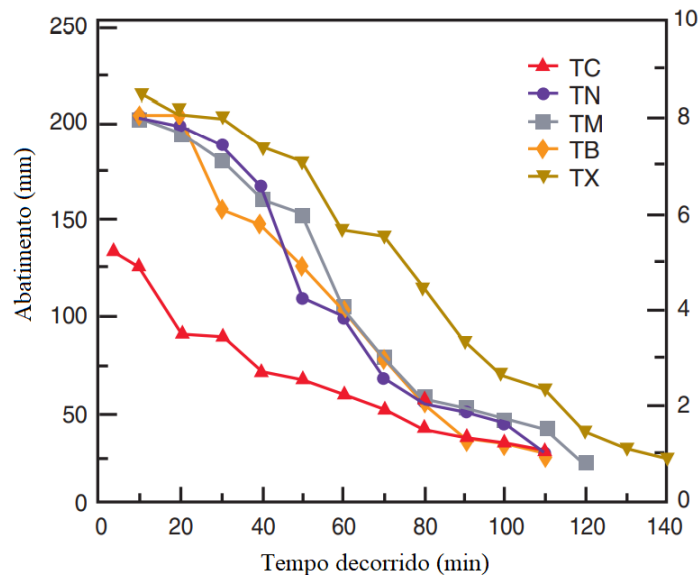
Segundo BERRY e MALHOTRA (1980), o acréscimo de cinza volante pode melhorar a plasticidade da pasta e melhorar a trabalhabilidade do concreto. Isso se deve à menor densidade da cinza volante comparativamente ao cimento, do efeito de diluição, no qual as partículas de cinza volante reduzem a floculação das partículas de cimento, e devido à lenta reação pozolânica nos primeiros dias. Além disso, a forma esférica facilita o movimento das partículas vizinhas. O referido estudo também discute sobre uma contradição encontrada na literatura, onde alguns estudos trazem uma perspectiva que a cinza volante demanda menos água devido ao refinamento dos poros e esfericidade das partículas, enquanto outros relatam que se deve aumentar a quantidade de água devido a maior área superficial da cinza volante.

Em relação aos concretos com adição de escória, usualmente consegue-se uma melhor trabalhabilidade, mas que piora com o aumento da finura da escória. Estudos também mostram que a trabalhabilidade pode aumentar devido a melhor distribuição das partículas cimentícias e características da superfície das partículas de escória (AMRAN et al., 2021).

MEGAT JOHARI *et al.* (2011) investigam a influência da adição de escória e de cinza volante na trabalhabilidade do concreto, comparando valores de abatimento em diferentes misturas. Concretos com escória tiveram uma melhoria considerável na fluidez, o que foi atribuído à melhor dispersão das partículas cimentícias, e pela superfície mais lisa das partículas de escória que absorvem menos água durante a mistura. Concretos com cinza volante também tiveram melhoria considerável na trabalhabilidade, o que foi explicado pela forma esférica, textura lisa e melhor distribuição de finos das partículas de cinza volante. Outro possível motivo apontado pelo estudo é que as cinzas volantes se comportariam como um superplastificante, na dispersão e adsorção das partículas de cimento. No entanto, o uso de cinzas volantes com altas quantidades de carbono não queimado e contendo partículas mais grosseiras pode resultar em maior consumo de água e perda de abatimento.

O uso de plastificantes como aditivo é uma forma usual de melhorar a trabalhabilidade de concretos, aumentando sua fluidez e permitindo inclusive uma redução da relação *a/c* sem perda de trabalhabilidade. A efetividade do uso dos superplastificantes melhora com o aumento do consumo de cimento e finos no concreto, também sendo influenciada pelo estado inicial do abatimento (KOSMATKA; PANARESE; KERKHOFF, 2002). O efeito do plastificante pode ser observado ao longo das duas primeiras horas após a aplicação na mistura, conforme apresentado na Figura 10. O abatimento é predominantemente maior nos concretos com plastificante (TN, TM, TB e TX) ao longo do tempo.

Figura 10 – Efeito do uso de superplastificantes na consistência do concreto



Fonte: adaptado de KOSMATKA *et al.* (2002, p.111)

2.4 Modelos de previsão

Relações matemáticas são comumente usadas para explicar o desenvolvimento da resistência à compressão a partir dos materiais constituintes do concreto. Trata-se de modelos obtidos a partir de ensaios experimentais, constituindo-se de relações empíricas e fenomenológicas. Essas correlações são viáveis para se determinar um traço inicial para dar partida em métodos de dosagem, mesmo que não leve em conta todos as variáveis envolvidas no problema.

A equação de Abrams é um exemplo de regressão linear que relaciona a resistência à compressão (em log) com a relação a/c (ABRAMS, 1919). Além desta e outras formulações clássicas, existem diversos estudos que desenvolvem modelos de regressão para estimar propriedades mecânicas do concreto. BHARATKUMAR *et al.* (2001) usam um método de dosagem por meio de regressão e chegam em resultados bem próximos dos experimentais. No estudo feito por ZAIN e ABD (2009), emprega-se uma regressão não linear múltipla pra estimar resistência à compressão em diferentes idades.

É importante notar que esses modelos fenomenológicos perdem a eficácia em problemas com um número grande de variáveis e cujas correlações são complexas de serem determinadas. Concretos de alto desempenho apresentam uma relação altamente não linear entre os consumos dos materiais constituintes e a resistência à compressão, de tal forma que o

uso de modelos convencionais não tem grande acuraria (CHOU; TSAI, 2012). Esta conclusão é compartilhada com o estudo de YEH *et al.* (2009), que comparam resultados de modelos de regressão e um modelo híbrido de Algoritmos Genéticos e Árvores de Expressão.

Para suprir essas limitações dos modelos de regressão convencionais, algoritmos de aprendizado de máquina para predição de propriedades do concreto vem sendo bastante empregados e é um tema em destaque na literatura. Tais algoritmos se adaptam bem para problemas de previsão de comportamento de concreto a partir de sua dosagem devido à capacidade de captar correlações não lineares entre as variáveis de entrada e de saída do modelo. Diferentes tipos de aprendizado de máquina são usados para estimar a resistência do concreto, como a Rede Neural Artificial, Máquinas de Vetores de Suporte, Árvores de Decisão e Algoritmos Genéticos (BEN CHAABENE; FLAH; NEHDI, 2020).

A predição de abatimento do tronco de cone por meio de aprendizado de máquina também se mostra bastante eficaz em alguns estudos. YEH *et al.* (2006), YEH *et al.* (2009) e ÖZTAŞ *et al.* (2006) usaram redes neurais para modelar o abatimento em função da quantidade dos materiais constituintes do concreto, relação água/cimento e relação plastificante/aglomerante. TIMUR *et al.* (2019), AMLASHI *et al.* (2019) e MOAYEDI *et al.* (2019) usam Rede Neural Artificial, Árvore de Regressão M5, Floresta Aleatória, Lógica Difusa e Máquina de Vetores de Suporte para estimar o abatimento.

Seguindo a estratégia adotada pelos artigos consultados, o presente trabalho usará modelos com Redes Neural Artificial, Árvore de Decisão e Máquina de Vetores de Suporte, que serão melhores detalhadas a seguir. O diferencial do presente trabalho, porém, é o emprego destes três algoritmos, buscando encontrar o que apresenta melhor desempenho para a previsão de resistência e abatimento. Além disso, é feita uma análise de sensibilidade para interpretar tais modelos.

2.4.1 Rede Neural Artificial

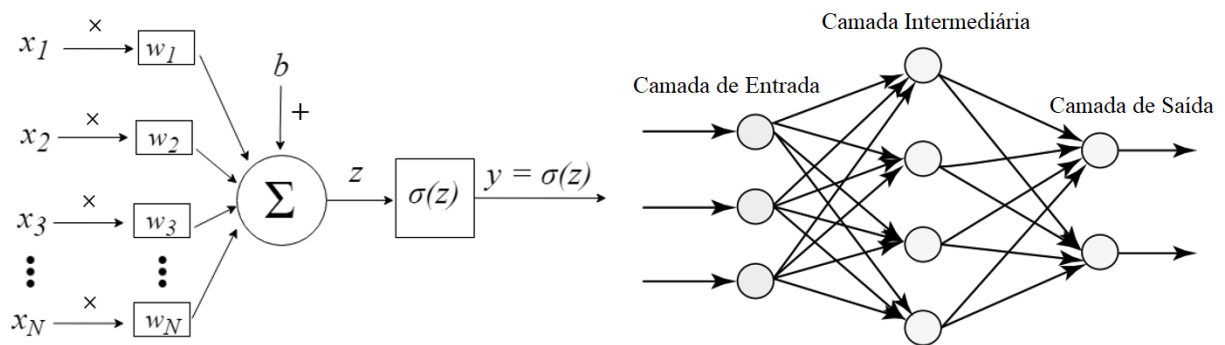
A Rede Neural Artificial (RNA) é uma técnica computacional inspirada no comportamento do cérebro humano que procura adquirir conhecimento a partir de respostas a estímulos externos. A rede consiste em um conjunto de neurônios que são interligados por múltiplas conexões. Atribui-se para cada ligação um peso que armazena o conhecimento adquirido, e para cada neurônio atribui-se uma função de ativação que processa a informação recebida (ABRAHAM, 2005).

As RNAs são bastantes exploradas na literatura para diversos problemas, pois possuem boa acurácia em sistemas naturais complexos que envolvem muitas variáveis, tal como no contexto da tecnologia do concreto. GARDNER e DORLING (1998) trazem uma revisão literária de estudos que usam RNAs em aplicações na ciência atmosférica, e DJAVANSHIR, CHEN e YANG (2021) mostram as aplicações na medicina, em diagnósticos.

No contexto da tecnologia do concreto, DEEPA *et al.* (2010) usam RNAs para previsão de resistência de concretos de alta performance e encontra bons resultados. CHITHRA *et al.* (2016) também procuram estimar a resistência de concretos, e comparam as redes neurais com modelos de regressão linear múltipla e demonstram que as RNAs apresentam melhores resultados. CHANDWANI, AGRAWAL e NAGAR (2015) usam RNAs para previsão de abatimento de tronco de cone em misturas prontas de concreto (do inglês, *ready-mix concrete*).

Nestes estudos, empregam-se as Multicamadas de *Perceptron* (do inglês, *Multi Layer Perceptron*), uma rede formada por neurônios denominados *perceptrons*. Cada *perceptron* computa um único valor de saída de acordo com um conjunto de valores de entradas e seus respectivos pesos, como pode ser observado na Figura 11. A rede é formada por uma ou mais camadas intermediárias, além da camada de entrada e saída.

Figura 11 – Representação esquemática do modelo matemático de um *perceptron* e da Multicamada de *perceptrons*



Fonte: adaptado de ABRAHAM (2005)

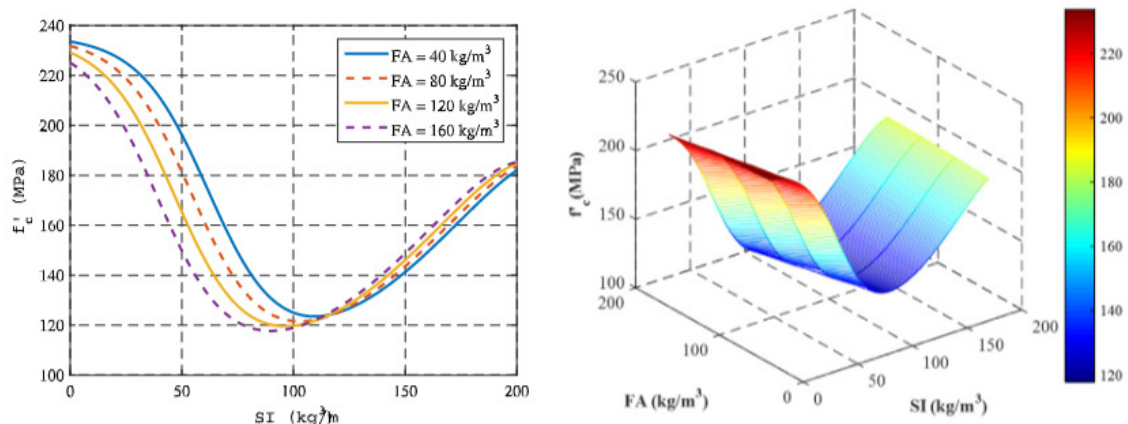
Os estímulos de entrada são representados pelo vetor \mathbf{x} e que são ponderados por um vetor de peso \mathbf{w} e somado a um limiar de ativação b (*bias*), gerando o potencial de ativação z . O neurônio processa o valor z pela sua função de ativação σ que retorna o valor de saída do sistema y . Algumas funções de ativação são a *softmax*, a tangente hiperbólica (*tanh*) e *relu* (do inglês, *Rectified Linear Unit*). Os vetores de peso \mathbf{w} e os limiares de ativação b são inicializados com valores arbitrários, logo não ideais para uma boa predição. Usualmente, emprega-se o

algoritmo de aprendizado supervisionado *backpropagation* que modifica os pesos das camadas com base no erro da rede. Trata-se de um processo iterativo com o cálculo de gradiente descendente para cada peso da rede, procurando minimizar assim o erro quadrático médio entre a saída da rede e saída esperada (ABRAHAM, 2005).

A biblioteca *Scikit-learn* (PEDREGOSA *et al.*, 2011) inclui algoritmos de Multicamadas de Perceptron. Os parâmetros de entrada para o algoritmo de classificação são: (i) número de neurônios e camadas; (ii) função de ativação para cada camada intermediária; (iii) função de otimização usada no *backpropagation*, podendo ser um método da família *quasi-Newton*, o algoritmo de gradiente descendente ou de gradiente estocástico. Estes são os mesmos parâmetros para o algoritmo regressão, mas a última camada não tem função de ativação atribuída. Ainda segundo PEDREGOSA *et al.* (2011), a grande vantagem do uso de Multicamadas de Perceptron é a capacidade de aprender funções não lineares. Contudo, algumas desvantagens incluem arbitrar certos hiperparâmetros como número de neurônios, camadas e interações, e que o modelo é sensível à escala das variáveis de entradas. Dessa forma, é necessário normalizar os dados de entrada para obter melhores resultados.

Costuma-se dizer que a RNA é uma ferramenta com natureza de caixa preta (do inglês, *black box*), pois pode ser difícil identificar quais variáveis são as mais importantes para a saída do modelo, e como são as funções matemáticas desenvolvidas internamente na rede. Uma forma de contornar este problema é o uso de análises de sensibilidades que identificam quais variáveis mais influenciam a saída da rede, explicados mais adiante na Metodologia. ABUODEH, ABDALLA e HAWILEH (2020) fazem um estudo de sensibilidade em cima de um modelo RNA que estima a resistência à compressão de concretos de alta resistência. Por exemplo, para uma relação água cimento constante, variou-se a quantidade de cinza volante em diferentes quantidades fixadas e sílica ativa. Este caso pode ser observado na Figura 12, onde FA designa as cinzas volantes e SI a sílica ativa.

Figura 12 – Estudo paramétrico do efeito da sílica ativa para diferentes quantidades de cinzas volantes na predição da resistência do concreto




Fonte: ABUODEH, ABDALLA e HAWILEH (2020)

2.4.2 Árvore de Decisão

BREIMAN *et al.* (1984) introduzem a Árvore de Decisão (do inglês, *Decision Tree*) como uma ferramenta usada em problemas de classificação e regressão. A partir de uma entrada e um conjunto de dados descritivos da situação, a árvore retorna um valor predito. A árvore executa uma série de testes para tomar uma decisão com base nos dados de entrada do modelo. Cada nó da árvore corresponde a um teste de valor relacionado a uma variável de entrada, e os ramos atribuídos ao nó são as possíveis respostas para o teste. Os nós finais, isto é, as folhas, determinam o valor de retorno do modelo. A Figura 13 exemplifica uma Árvore de Decisão, onde as variáveis de entrada X_1 e X_2 são testadas, e dependendo dos resultados de cada teste, uma das folhas R_1 a R_5 é a saída do modelo. Percebe-se que a Árvore de Decisão divide o domínio dos valores previstos em diferentes níveis (planos), trazendo uma forma de predição mais complexa e flexível que uma simples regressão linear (plano único) não seria capaz de descrever.

Figura 13 – Exemplo de Árvore de Decisão



Fonte: HASTIE et al. (2009)

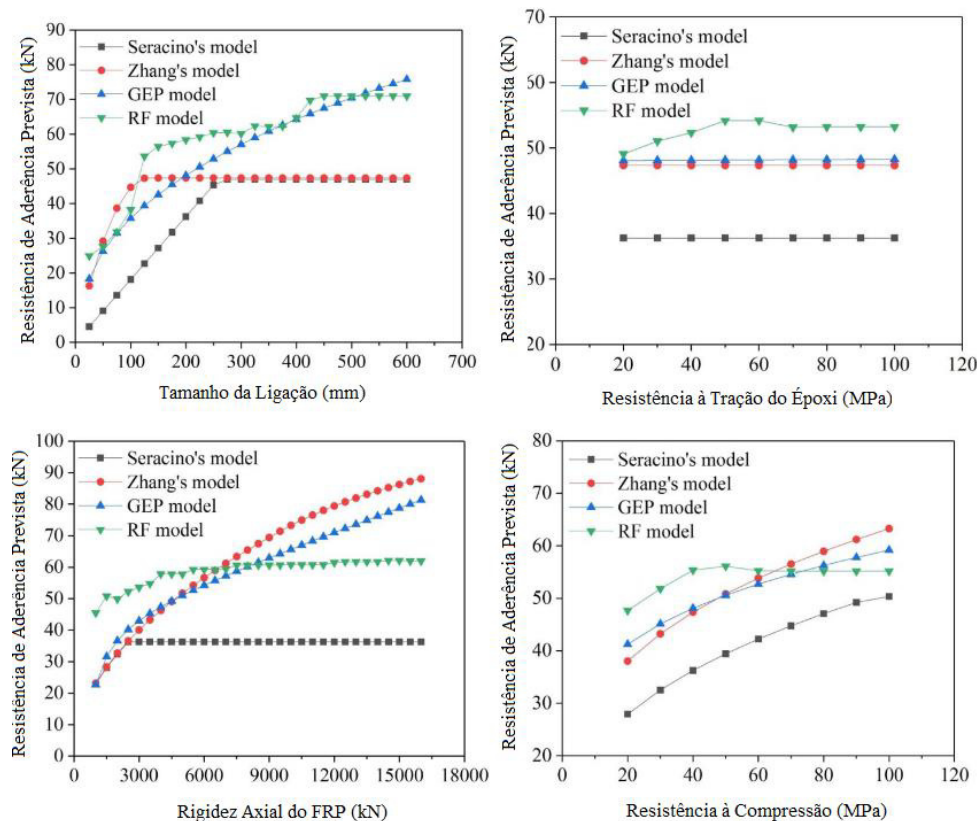
As Árvores de Decisão apresentam bons resultados para os dados disponíveis, pois têm a capacidade de se adaptar bem ao conjunto de dados usados no treino. Contudo, não se observa esta flexibilidade em classificar novos dados e raramente se encontra uma melhor precisão na etapa de pós validação (HASTIE *et al.*, 2009, p. 352). Neste contexto, a Floresta Aleatória (RF, do inglês *Random Forest*) é um algoritmo bastante explorado na literatura que visa trazer mais flexibilidade para a predição, pois combina várias árvores de decisão, cada uma construída por um subconjunto dos dados originais obtidos pelo método de *bagging*. O resultado do modelo é dado pela média dos resultados individuais de cada árvore de decisão (HASTIE *et al.*, 2009).

A RF é bastante empregada nas pesquisas de predição da resistência do concreto. HAN *et al.* (2019) usaram o modelo para predição de resistência à compressão de concretos de alta performance. MANGALATHU e JEON (2018) fizeram o mesmo para predição de resistência à cisalhamento de juntas viga-pilar de concreto armado. ZHANG *et al.* (2019) previram resistência à compressão de concretos leves autoadensáveis. ZHANG, AKBER e ZHENG (2022) usaram a Floresta Aleatória para estimar o abatimento do tronco de cone.

A biblioteca *Scikit-learn* (PEDREGOSA *et al.*, 2011) inclui algoritmos para criar árvores de classificação e regressão. Os parâmetros de entrada são: (i) um critério para mensurar a qualidade ao inserir novas partições na árvore, podendo ser a entropia, a perda logarítmica, ou a impureza de Gini; (ii) uma estratégia usada para escolher a partição em cada nó; (iii) o maior tamanho da árvore em profundidade; dentre outros. No caso da RF, é necessário indicar o número de árvores na floresta.

Assim como a Rede Neural Artificial, a Floresta Aleatória não pode ser interpretada diretamente e faz-se necessária uma análise de sensibilidade para extrair conclusões físicas do modelo. ZHANG e XUE (2021) desenvolvem uma Floresta Aleatória para prever a resistência de aderência de fibras ao concreto e faz um estudo paramétrico, variando cada variável de entrada e montando gráficos com os valores estimados de resistência, ver Figura 14.

Figura 14 – Representação esquemática do modelo matemático de um *perceptron* e da Multicamada de *perceptrons*



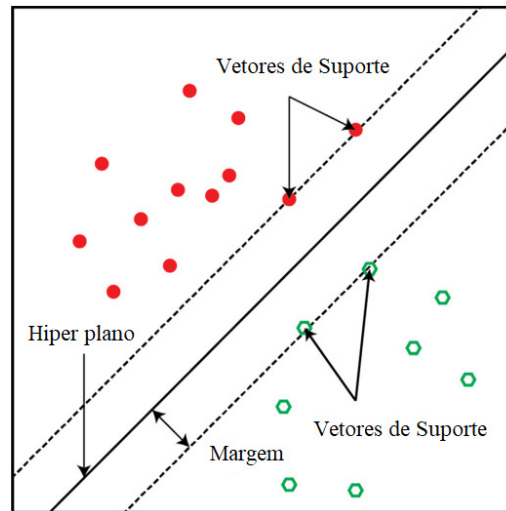
Fonte: adaptado de ZHANG e XUE (2021)

2.4.3 Máquina de Vetores de Suporte

O algoritmo de Máquina de vetor de suporte (SVM, do inglês *Support Vector Machine*) foi proposto por VAPNIK (1998) e pode ser usado para classificação e regressão. O SVM constrói hiperplanos em um espaço n-dimensional e tem por objetivo maximizar as margens, isto é, a distância entre o hiperplano e os pontos de cada classe. Após estabelecer os hiperplanos, os vetores mais próximos às margens, chamados de vetores de suporte, são os únicos usados na classificação, conforme ilustrado na Figura 15.

Funções *kernel* podem ser aplicadas em um conjunto de dados não linearmente separáveis. Essas funções transformam os pontos, tornando possível a separação por um hiperplano. As mais usuais são polinômios, sigmoide e bases radiais (BEN CHAABENE; FLAH; NEHDI, 2020).

Figura 15 – Hiper planos de classificação




Fonte: adaptado de BEN CHAABENE, FLAH e NEHDI (2020)

O SVM tem aplicações com bons resultados para predição de resistência de concretos com alta resistência (CHOU et al., 2011), e também para predição de abatimento de concretos com acréscimo de bio-aditivos (DHANPAT; HIGGINSON; BROOKS, 2021).

O parâmetro de regularização C controla tolerância em aceitar uma classificação errada, em prol de uma melhor capacidade de generalização do modelo. A Figura 16 exemplifica este conceito, onde, para um C igual a 100, classificam-se bem todos os dados, mas perde-se a capacidade de generalizar o modelo para novas entradas. Um menor valor de C implica um modelo que comete mais violações de margem, entendendo certos pontos como ruído. O valor ideal de C depende de cada sistema e sua escolha também é um problema de otimização de hiperparâmetros, assim como os já comentados para RNA.

Figura 16 – Parâmetro de regularização no modelo SVM



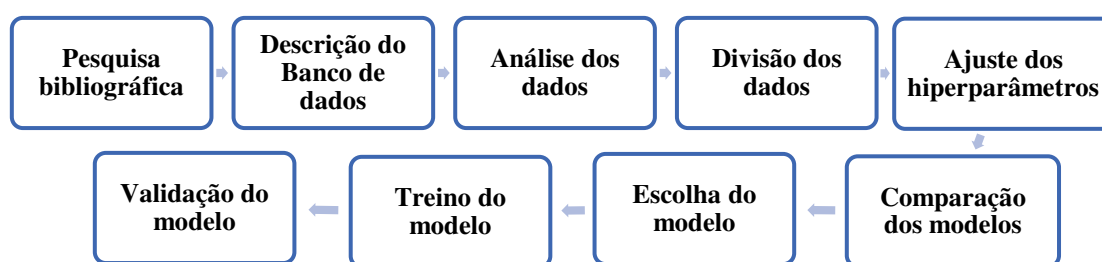
Fonte: elaborado pelo autor

A biblioteca *Scikit-learn* (PEDREGOSA *et al.*, 2011) contém o algoritmo SVM para regressão e classificação. Os parâmetros de entrada do modelo são: (i) parâmetro C de regularização; (ii) função *kernel*; (iii) coeficiente *gamma* atribuído à função *kernel*; dentre outros. PEDREGOSA *et al.* (2011) recomendam a normalização dos dados, pois o algoritmo é afetado pela escala das variáveis de entrada.

3 METODOLOGIA

Os passos adotados para criação e descrição do banco de dados, e desenvolvimento dos modelos de predição são apresentados na Figura 17. Em seguida, cada etapa será explicada em detalhes nas subseções deste Capítulo 3.

Figura 17 – Fluxograma da metodologia para desenvolvimento dos modelos



Fonte: Elaborado pelo autor

3.1.1 Pesquisa Bibliográfica

A pesquisa bibliográfica procura dados de dosagens de concretos que detalhem o consumo dos materiais usados no preparado do concreto, além do resultado experimental da resistência à compressão e/ou abatimento de tronco de cone. Dessa forma, os bancos são criados com dados já publicados na literatura. Em outras palavras, foram utilizados dados secundários nesta pesquisa.

A busca foi feita principalmente nas plataformas *Science Direct*, Periódicos da CAPES, e *Google Scholar*, que contêm publicações de artigos científicos com resultados experimentais. As expressões chaves das pesquisas foram: *concrete*, *compressive strength*, *slump*, *data*, *prediction*, *mix design*, e similares. Buscou-se pelos artigos encontrados na pesquisa inicial, assim como suas referências. Focou-se em artigos em que houvesse tanto as informações de resistência ou abatimento quanto as informações necessárias sobre a composição dos concretos. O processo foi repetido até que não se encontrassem mais novos artigos úteis para a organização dos bancos de dados e uma vez que houvesse uma ordem de mil instâncias (diferentes concretos/idades) para cada um dos problemas (previsão de resistência e previsão de abatimento de tronco de cone).

O banco de dados final deve ser formado preferencialmente por concretos convencionais, visto que outras ferramentas de previsão desenvolvidas pelo Grupo de Estudo de Reologia dos Materiais (ReoM) são focadas em concretos especiais, como concretos de ultra alto desempenho (LOPES, 2022), concretos com fibras (SILVA et al., 2022), autoadensáveis (TARGINO et al., 2021) e pesados (INGRID; TALLIS; WANNER, 2021). Dessa forma, artigos que tratavam de concretos especiais não foram considerados na pesquisa.

3.1.2 Descrição do Banco de Dados

No total, 7 estudos com resultados experimentais de dosagem foram explorados para obter os dados necessários à construção do banco de dados. Alguns deles já possuíam organização própria de outros bancos de dados, reagrupando vários outros trabalhos. Os trabalhos dos quais foram retirados os dados investigados nesta pesquisa estão identificados na Tabela 4, assim como a quantidade total de instâncias obtidas. No Capítulo 4 será feito um tratamento desses dados, como a remoção de CAD com resistência superior a 55 MPa.

Tabela 4 - Identificação dos bancos de dados

Banco de Dados	Referência Bibliográfica	Instâncias resistência	Instâncias abatimento
1	(YEH, 1998)	1030	-
2	(ONER; AKYUZ; YILDIZ, 2005)	56	28
3	(YEH, 2009)	-	103
4	(DURÁN-HERRERA et al., 2011)	122	18
5	(QUAN; KASAMI, 2014)	63	21
6	(ABDELATIF et al., 2018)	721	495
7	(YANG; AN; DU, 2021)	-	130
Total		1992	795

Fonte: elaborado pelo autor

Entende-se por instância uma dosagem de concreto com dados de consumo de cimento, agregado graúdo, agregado miúdo, água, aditivos e adições, além do dado referente à resistência ou abatimento. Em se tratando de resistência à compressão, uma dosagem pode ser avaliada em diferentes idades do concreto, e pode gerar mais de uma instância no banco de dados. No caso do abatimento, uma dosagem sempre corresponde à uma instância.

Os estudos dos quais foram coletados os dados são detalhados a seguir, na ordem mostrada na Tabela 4.

O estudo proposto por YEH *et al.* (1998) reúne dados de 17 fontes independentes e constrói com estes dados modelos de predição de resistência usando RNAs. Como os dados

foram coletados de diferentes estudos, os autores comentam que o banco de dados contém diferentes tipos de agregados e com diferentes tamanhos e formatos. Alguns dados de CV não tinham sua classe especificada. Os plastificantes pertencem à diferentes fabricantes e possuem composições químicas variadas.

ONER *et al.* (2005) estudam impacto do uso de cinza volante na resistência à compressão do concreto. No estado fresco, mediu-se o abatimento do tronco de cone, e para o estado endurecido, foram feitas curas de 28 e 180 dias antes de serem realizados os testes de resistência. O cimento usado é o Portland CEM I 42,5. O agregado graúdo é formado por calcário triturado menores que 12 mm. Os agregados miúdos empregados foram areia de quartzo e calcário triturado com menor módulo de finura. A cinza volante pertence à classe F da ATSM.

YEH *et al.* (2009) desenvolvem redes neurais para estimar o abatimento do concreto. As amostras foram criadas em um ambiente de dosagem bem controlado, explorando diferentes relações água cimento e quantidade de plastificante. O cimento usado é o Portland do tipo I da ASTM C150, e o plastificante é do Tipo G da ASTM C 494 (CONSHOCKEN, 2004).

DURÁN-HERRERA *et al.* (2011) investigam concretos com alta porcentagem de cinza volante que apresentem altos valores de abatimento. O cimento usado é do tipo IP (MS) da ASTM C595 que é uma classe de cimento pozolânico. A cinza volante pertence à classe F da ASTM C 618. O plastificante usado é do tipo F da ASTM C 494. Os agregados são formados por areia calcária triturada seguindo as especificações ASTM 33.

QUAN *et al.* (2014) estudaram a durabilidade do concreto com adição de cinza volante. As misturas estudadas são formadas por cimento Portland comum, agregado fino areia de montanha com módulo de finura, agregado graúdo é pedra britada.

O banco de dados apresentado por ABDELATIF *et al.* (2018) possui mais de 1000 registros de experimentos com concreto realizados no Sudão ao longo de 10 anos. Um pré-tratamento foi feito dentre os dados originais, selecionando apenas dosagens que não usavam aditivos, pois considerá-las adicionaria inúmeras variáveis de projeto devido à diversidade de aditivos usados. O cimento utilizado é o Portland Comum.

YANG *et al.* (2021) empregam dois tipos de cascalho e areia, e tem por objetivo estudar o efeito que cada tipo de agregado tem na trabalhabilidade do concreto. Contudo, esta classificação em tipos de agregado não é relevante para o objetivo do presente trabalho e é desconsiderada. Os dois grupos de cascalho são classificados apenas como agregado graúdo, e os dois tipos de areia são classificadas apenas como agregado miúdo. O cimento utilizado é o CEM I 42,5. O plastificante usado pertence à classe G da ASTM C 494.

No presente trabalho, os modelos de predição não consideram as características físicas dos agregados, como módulo de finura, dimensão máxima, e natureza, pois essa informação estava presente em apenas uma parte dos estudos mencionados acima. As classificações da cinza volante, escória e plastificante também não serão considerados como variáveis de entrada pelo mesmo motivo.

Em suma, as variáveis de entrada para os modelos de previsão de resistência à compressão são os consumos de água, cimento, cinza volante, escória, agregado graúdo, agregado miúdo, plastificante e idade. Para os modelos de previsão de abatimento de tronco de cone, as variáveis são as mesmas, com exceção da idade do concreto.

3.1.3 Análise dos Dados

A análise de dados é feita por uma análise exploratória que investiga o conjunto de dados para encontrar anomalias (*outliers*), descobrir padrões de dosagem e desenvolver hipóteses para entender a relação entre os dados. A visualização dos dados é feita com a ajuda de gráficos estatísticos como *boxplots*, *pairplots* e histogramas da biblioteca *Scikit-learn* (PEDREGOSA *et al.*, 2011).

A análise de *outliers* é feita por meio de *boxplots* com o consumo dos materiais. Instâncias com consumos atípicos são excluídas do banco de dados por tratarem de dosagens atípicas que podem prejudicar o treino dos modelos. Contudo, uma instância *outlier* não deve ser retirada imediatamente, pois é importante observar se existem outras instâncias *outliers* na mesma faixa de consumo, e então verificar se estas pertencem à um estudo que propõe um padrão de dosagem, mesmo que atípico. Dessa forma, caso exista um grupo de *outliers* que acrescentem uma interpretação física ao modelo, este não é removido.

3.1.4 Divisão dos Dados

As instâncias dos bancos de dados são divididas em dois conjuntos. Os dados de treino correspondem a 80% do total e são usados para o ajuste de hiperparâmetros e treino dos modelos. Os dados de teste são usados apenas na etapa final para aferir o desempenho do modelo com dados nunca vistos, com base nos indicadores adotados na otimização de hiperparâmetros descrita no tópico a seguir. Além disso, os dados são normalizados, pois os modelos RNA e SVM podem ser afetados pela escala dos dados de entrada. A normalização consiste em transformar o conjunto de dados de cada variável de entrada com a média igual a 0 e a variância unitária.

3.1.5 Ajuste de Hiperparâmetros

A otimização dos hiperparâmetros (em inglês, *tuning*) consiste em buscar uma combinação de parâmetros que minimize uma função de critério, sendo o MAE (do inglês, *Mean Absolut Error*) e a acurácia escolhas usuais para regressão e classificação, respectivamente. O algoritmo *GridSearchCV* da biblioteca *Scikit-learn* faz esta busca usando o *5-fold Cross Validation* para averiguar o desempenho de cada modelo criado (PEDREGOSA *et al.*, 2011). Os valores candidatos de cada hiperparâmetro são escolhidos arbitrariamente dentro da faixa de valores usuais, conforme apresentado na Tabela 7.

É importante ressaltar que o *5-fold Cross Validation* é uma técnica empregada para avaliar o desempenho de modelos. O método consiste em dividir o conjunto de dados em 5 subconjuntos. Em uma primeira iteração, o primeiro subconjunto é usado para teste e os 4 restantes para treino. Na segunda iteração, o segundo subconjunto é usado para teste os 4 restantes para treino, e isto é feito até completar cinco iterações. No final, geram-se 5 resultados de teste dos quais pode-se extrair uma média para uma métrica de desempenho (FUSHIKI, 2011). Neste trabalho, o *5-fold Cross Validation* é aplicado sobre o conjunto de treino, com intuito de evitar o ajuste dos hiperparâmetros para o conjunto de teste.

Tabela 5- Valores de hiperparâmetros avaliados para cada modelo

Modelo	Hiperparâmetros	Valores
RNA	função de ativação	<i>relu</i> , <i>softmax</i> e <i>tanh</i>
	Número de neurônios	1 camada: 3, 5, 10, 32, 64 e 100 2 camadas: 32 e 64 em cada
RF	função critério	erro quadrático, erro absoluto e <i>poisson</i>
	profundidade máxima	5, 10, 25, 50 e 100;
	número de árvores	5, 10, 50 e 250
SVM	função <i>kernel</i>	sigmoide e base radial
	<i>C</i>	0,1, 0,5, 1, 5, 10, 50 e 100;
	<i>gamma</i>	0,1, 0,5, 1, 10, 50 e 100.

Fonte: elaborado pelo autor

3.1.6 Comparação dos Modelos

Os resultados dos modelos são comparados com base em métricas estatísticas usuais na literatura. Os modelos de classificação são avaliados pela acurácia, precisão, *recall* e *F1-score*. Os modelos de regressão são avaliados pelo RMSE (do inglês, *Root Mean Squared Error*) e MAE. Esta seção definirá as métricas adotadas.

3.1.6.1 Modelos de Classificação

As métricas de classificação são formuladas a partir de uma matriz de confusão como a mostrada na Figura 18. Esta matriz é uma tabela que indica os erros e acertos do modelo, comparando as classes previstas com as classes reais conhecidas.

Figura 18 – Matriz de confusão

Classificações Reais	Classes	a	b	c	d
	a	TN	FP	TN	TN
	b	FN	TP	FN	FN
	c	TN	FP	TN	TN
	d	TN	FP	TN	TN
Classificações Previstas					

Fonte: Elaborado pelo autor

Os Verdadeiros Positivos (do inglês, TP – *True Positive*) de uma classe são os casos em que o modelo previu corretamente a classe, ou seja, corresponde ao valor da diagonal da matriz. Os Falsos Positivos (FP) de uma classe são os casos em que o modelo prediz esta classe para instâncias que pertencem a classes diferentes, ou seja, a soma de todos os valores da coluna da matriz que não sejam o TP. Por exemplo, o modelo classifica um concreto como C25, mas a classe correta seria C20, C30, C35, C40 ou C45.

Os Falsos Negativos (FN) de uma classe são os casos em que o modelo prediz outras classes para instâncias que pertencem a classe em questão. Por exemplo, o modelo classifica concretos em S10, S50 e S200, mas a classe correta seria a S100.

Os Verdadeiros Negativos (do inglês, TN – *True Negative*) são todos os FN e FP, isto é, a soma de todos os valores da linha e da coluna, exceto o VP. Com base nessas notações, consegue-se calcular as métricas, conforme a Eq. 1, Eq. 2, Eq. 3 e Eq. 4.

$$\text{Eq. 1} \quad \text{Acurácia} = \frac{TP+TN}{TP+TN+FP+FN}$$

$$\text{Eq. 2} \quad \text{Precisão} = \frac{TP}{TP+FP}$$

$$\text{Eq. 3} \quad \text{Recall} = \frac{TP}{TP+FN}$$

$$\text{Eq. 4} \quad F1\text{-score} = 2 \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$$

A acurácia costuma ser um indicador de desempenho geral do modelo, pois ela calcula dentre todas as classificações, quantas foram feitas corretamente. Enquanto isso, a precisão considera apenas os TP e FP, isto é, os valores de uma coluna da matriz. É melhor empregada para avaliar sistemas em que os FP são mais prejudiciais que os FN. De forma semelhante, o *recall* considera apenas os TP e FN, e é melhor empregado quando os FN são mais prejudiciais que os FP. O *F1-score* é uma média harmônica entre a precisão e o *recall*, e um baixo valor é um indicativo que ou a precisão ou o *recall* está baixo.

Em relação aos modelos desenvolvidos neste trabalho, a precisão e o *recall* possuem o mesmo nível de importância para mensurar o desempenho. Como as ferramentas de predição são usadas para encontrar um traço inicial, os FN e os FP não são tão prejudiciais na prática, pois haverá ajustes do traço inicial para produzir o resultado final da dosagem, que consistem em uma composição ajustada. Se a ferramenta fosse usada para determinar um traço final, a precisão seria mais importante, pois os FN são mais prejudiciais. Por exemplo, espera-se que ao se classificar um concreto como C35, a precisão seja alta para evitar concretos com menor classe.

3.1.6.2 Modelos de Regressão

O RMSE é a medida que calcula a raiz quadrada da média das diferenças ao quadrado, entre os valores reais y e as predições \hat{y} . Os erros são elevados ao quadrado antes do cálculo da média, e, portanto, diferentes pesos são atribuídos na soma. Assim, o RMSE penaliza os erros de maior magnitude, então é mais sensível a previsões que tenham mais *outliers*. O RMSE para n observações é determinado pela Eq. 5:

$$\text{Eq. 5} \quad \text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2}$$

O MAE calcula o erro médio absoluto entre os valores reais e predições e não penaliza erros de grande magnitude como o RMSE, como mostrado pela Eq. 6.

$$\text{Eq. 6} \quad \text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j|$$

3.1.7 *Cr terio de Escolha dos Modelos*

Para os modelos de classifica o, buscou-se o modelo com maior acur cia, precis o, *recall* e *F1-score*, enquanto que para os modelos de regress o, buscou-se pelo modelo com menor RMSE e MAE.

3.1.8 *Valida o dos Modelos*

Nesta etapa final, os modelos s o avaliados com dados de teste, e verifica-se se as m tricas ficam pr ximas dos valores encontrados no treino. Caso as m tricas indiquem um bom desempenho, conclui-se que o modelo   generalizado o suficiente para prever dados nunca vistos.

Al m disso,   fundamental verificar se o modelo explica bem o fen meno f sico do sistema, isto  , se as previs es de resist ncia e abatimento s o bem explicadas para diferentes misturas e em conformidade com explica es sobre o efeito de cada par metro de entrada. Foi explorada uma gama de misturas que n o existem necessariamente nos dados de treino e teste, a fim de estudar a usabilidade e interpretabilidade do modelo. Buscou-se investigar misturas com consumos usuais para cada material constituinte, evitando assim extrapolar o dom nio das vari veis de entrada ao qual o modelo foi treinado.

3.1.8.1 PDP e ICE

O Gr fico de Depend ncia Parcial (do ingl s, PDP – *Partial Dependence Plot*) mostra o efeito marginal de uma vari vel de entrada sobre as previs es de um modelo. Normalmente, esses gr ficos s o usados para avaliar a sensibilidade de um modelo para cada vari vel de entrada. Isso pode ser visualizado pela inclina o da curva, quanto mais positiva, mais importante a vari vel   para explicar o fen meno (FRIEDMAN, 2001).

Semelhante a gr fico PDP, o gr fico de Expectativa Condicional Individual (do ingl s, ICE – *Individual Conditional Expectation*) tamb m mostra a depend ncia entre a sa da do modelo e a vari vel de entrada de interesse. Contudo, ao contr rio do PDP, que mostra um efeito m dio para a vari vel, o gr fico ICE mostra a depend ncia do modelo para a vari vel separadamente com uma curva para cada inst ncia. Assim, consegue-se identificar diferentes padr es para uma vari vel de interesse, pois cada inst ncia   visualizada (GOLDSTEIN et al., 2015).

Apesar dos gr ficos PDP e ICE elucidarem o comportamento m dio global e individual para cada vari vel de entrada, existem desvantagens em usar apenas estas

ferramentas para interpretar o modelo. Nestes gráficos, assume-se que as variáveis de entrada são independentes, mas na verdade os consumos dos materiais dependem entre si, como explicado a seguir. Além disso, o número máximo de variáveis que podem ser analisadas simultaneamente são duas, devido à capacidade cognitiva humana em interpretar gráficos de até 3 dimensões.

3.1.8.2 Análise Paramétrica e Análise de Sensibilidade

A interpretação do modelo é feita por análise de sensibilidade, isto é, explorar diferentes dosagens com o objetivo de estudar como cada material influencia na saída do modelo, além de procurar explicar o padrão observado com constatações da literatura. Contudo, ao variar o consumo de um material específico, a quantidade dos outros materiais também deve mudar a fim de manter o volume da mistura constante. Aumentar o consumo de um dado material constituinte do concreto incorreria em aumentar a massa ocupando o mesmo volume, portanto incorrendo indevidamente em um aumento da compactidade do material. Dessa forma, é necessário definir um procedimento que evite dosagens com valores irreais de consumos dos materiais, isto é, uma análise paramétrica para o consumo dos materiais considerando essa compensação. Nesta perspectiva, faz-se necessário definir um traço de referência que será modificado conforme o objetivo da análise de sensibilidade, e reajustado de acordo com procedimento da análise paramétrica.

3.1.8.2.1 Traço de Referência

Adotou-se um traço de referência comum na literatura e presente no banco de dados, o traço em massa 1:2:3:0,5 sem acréscimo de aditivos e adições. Os consumos são definidos com base no *boxplot* referente a cada material, buscando valores próximos ao percentil 50. Os consumos adotados e a densidade relativa de cada material são apresentados na Tabela 6.

Tabela 6- Consumo padrão e densidade relativa para cada material

Material	Consumo (kg/m³)	Densidade Relativa
Cimento	350	3,15
Água	175	1,00
Agregado Miúdo	700	2,65
Agregado Graúdo	1050	2,70

Fonte: elaborado pelo autor

As densidades relativas dos materiais são definidas com base nas descrições dos materiais apresentadas nos artigos que compõem o banco de dados, arbitrando valores dentro

de uma faixa comum a todos que apresentaram tal informação. Como comentado na referência bibliográfica, o traço em massa é denotado por $1:a:b/a/c$. Para um determinado consumo de cimento C (em kg/m^3), os volumes ocupados pelos materiais são calculados pelas formulações da Eq. 7:

$$\text{Eq. 7} \quad \left\{ \begin{array}{l} V_c = \frac{1}{\rho_c} C \\ V_a = \frac{(a/c)}{\rho_a} C \\ V_{am} = \frac{a}{\rho_{am}} C \\ V_{ag} = \frac{b}{\rho_{ag}} C \end{array} \right.$$

onde V_c , V_a , V_{am} e V_{ag} são os volumes de concreto, água, agregado miúdo e agregado graúdo respectivamente. Assim, o traço em volume é designado pela Eq. 8:

$$\text{Eq. 8} \quad 1: a \left(\frac{\rho_{am}}{\rho_c} \right) : b \left(\frac{\rho_{ag}}{\rho_c} \right) : \left(\frac{a}{c} \right) \left(\frac{\rho_a}{\rho_c} \right)$$

Substituindo os valores conhecidos, o traço de referência em volume é $1:1,68:2,57:0,16$.

3.1.8.2.2 Análise Paramétrica

Ao acrescentar uma quantidade m (em kg) de um material M (cimento, água ou agregados), procura-se determinar a massa que deve ser retirada de cada material na mistura para que o volume permaneça constante. O primeiro passo consiste em determinar o volume V_M ocupado pela massa m , conforme a Eq. 9.

$$\text{Eq. 9} \quad V_M = \frac{m}{\rho_M}$$

onde ρ_M é a massa específica do material M .

Em seguida, deve-se o ratear o volume V_M para cada material na mistura. Arbitra-se que a proporção do rateio seja a mesma que o traço em volume, pois assim retira-se uma porção maior dos materiais mais presentes na mistura, como o agregado graúdo, e menos dos materiais com menor proporção na mistura, como a água. Dessa forma, os volumes de rateio V'_c , V'_a , V'_{am} e V'_{ag} são determinados pelos coeficientes do traço em volume, e as massas m'_c , m'_a , m'_{am} e m'_{ag} a serem retiradas do sistema são calculadas sabendo-se os volumes e os pesos específicos.

3.1.8.2.3 Análise de Sensibilidade

Um caso de aplicação de análise de sensibilidade aplicando a análise paramétrica consiste em aumentar em m massa de água no sistema para estudar o efeito do consumo de água no resultado do modelo. O volume V_M acrescentado ao sistema é calculado pela Eq. 10.

$$\text{Eq. 10} \quad V_M = \frac{m}{\rho_a}$$

O rateio do volume V_M é calculado pela proporção de cada material no traço em volume, conforme a Eq. 11, Eq. 12 e Eq. 13.

$$\text{Eq. 11} \quad V'_c = \left(\frac{1}{1+1,68+2,57} \right) V_M = 0,19V_a$$

$$\text{Eq. 12} \quad V'_{am} = \left(\frac{1,68}{1+1,68+2,57} \right) V_M = 0,32V_a$$

$$\text{Eq. 13} \quad V'_{ag} = \left(\frac{2,57}{1+1,68+2,57} \right) V_M = 0,49V_a$$

Finalmente, calcula-se a massa que se deve retirar de cada material, de acordo com a Eq. 14, Eq. 15 e Eq. 16.

$$\text{Eq. 14} \quad m'_c = 0,19m \frac{\rho_c}{\rho_a}$$

$$\text{Eq. 15} \quad m'_{am} = 0,32m \frac{\rho_{am}}{\rho_a}$$

$$\text{Eq. 16} \quad m'_{ag} = 0,49m \frac{\rho_{ag}}{\rho_a}$$

Dessa forma, consegue-se estudar o efeito do aumento do consumo de água na saída do modelo, mas para dosagens reais que consideram que o aumento do consumo de água em um volume fixo deve ser compensado pela saída de material em massa, de maneira a manter o mesmo volume.

Outra análise comum consiste em manter o consumo de cimento fixado enquanto se aumenta o consumo de outro material, de tal forma que o cimento não participa do rateio do volume V_M . Por exemplo, procura-se aumentar em m a massa de agregado miúdo, mantendo o consumo de cimento no padrão de 350 kg/m^3 . O volume V_M acrescentado ao sistema é calculado pela Eq. 17.

$$\text{Eq. 17} \quad V_M = \frac{m}{\rho_{am}}$$

O rateio do volume V_M é dado pela Eq. 18 e Eq. 19.

$$\text{Eq. 18} \quad V'_{ag} = \left(\frac{2,57}{2,57+0,16} \right) V_M = 0,94V_M$$

$$\text{Eq. 19} \quad V'_a = \left(\frac{0,16}{2,57+0,16} \right) V_M = 0,06V_M$$

Calcula-se a massa que se deve retirar de cada material pela Eq. 20 e Eq. 21.

$$\text{Eq. 20} \quad m'_{ag} = 0,94m \frac{\rho_{ag}}{\rho_{am}}$$

$$\text{Eq. 21} \quad m'_a = 0,06m \frac{\rho_a}{\rho_{am}}$$

Quando o material M for cinza volante ou escória, a substituição do volume V_M é feita sempre por cimento, cuja massa a ser retirada do sistema é calculado pela Eq. 22.

$$\text{Eq. 22} \quad m_c = m \frac{\rho_M}{\rho_c}$$

Em suma, existem três tipos de análise paramétrica: (i) Ao alterar o consumo de um dos quatro materiais principais, seja o cimento, a água, agregado graúdo ou miúdo, é necessário alterar a quantidade dos três materiais restantes. (ii) Caso o cimento seja mantido fixado, alterar apenas a quantidade dos dois materiais restantes. (iii) E ao acrescentar cinza volante ou escória, retirar apenas o cimento da mistura na compensação.

4 ANÁLISE EXPLORATÓRIA

4.1 Banco de dados para previsão de resistência

A Tabela 7 descreve o banco de dados para previsão de resistência após a junção dos dados dos diferentes estudos da Tabela 7. Um total de 1992 instâncias são listadas, sendo 1271 com adição de cinzas volantes e 1030 com adição de escória granulada de alto forno e plastificante.


Tabela 7- Banco de dados final para previsão de resistência à compressão


Consumo de cada material (kg/m ³)									
	Cimento	Água	Agregado Miúdo	Agregado Graúdo	Cinza volante	Escória	Plastificante	Idade (dias)	fc(Mpa)
Qtd.	1992	1992	1992	1992	1271	1030	1030	1992	1992
Mín.	93	100	275	436	0	0	0	1	1
Máx.	540	290	1293	1510	319	359	32	365	83
Média	309	185	763	1022	64	74	6	35	32
Desvio	91	21	116	160	73	86	6	54	14

Fonte: Elaborado pelo autor

Inicialmente, verifica-se se o banco de dados possui *outliers* para o consumo de cada material que podem prejudicar no treino dos modelos. A Figura 19 apresenta os *boxplots* dos principais insumos.

Figura 19 – *Boxplots* com dados de consumo de cimento, água e agregados do banco de dados de resistência





Fonte: elaborado pelo autor

Não se observa *outliers* para o consumo de cimento. Em relação ao consumo de água, inúmeros *outliers* estão destacados, mas a maioria estão agrupados no mesmo intervalo. Em particular, dosagens com consumo de água abaixo de 130 kg/m^3 ocorrem sempre com um alto consumo de plastificante, com média de $13,5 \text{ kg/m}^3$, e geram concretos com resistência média de $38,75 \text{ MPa}$. Optou-se por não excluir estas instâncias, pois elas acrescentam uma interpretação física ao modelo, que o uso de plastificantes traz uma grande redução no consumo de água, mantendo uma alta classe de resistência.

Em relação aos agregados, os *outliers* mostrados pertencem ao estudo que propõe dosagens com menor teor de agregado graúdo, aliado ao consumo de mais agregado miúdo e cinza volante (ONER; AKYUZ; YILDIZ, 2005). Dessa forma, estas instâncias não foram excluídas, pois também trazem um padrão de dosagem interessante para a análise.

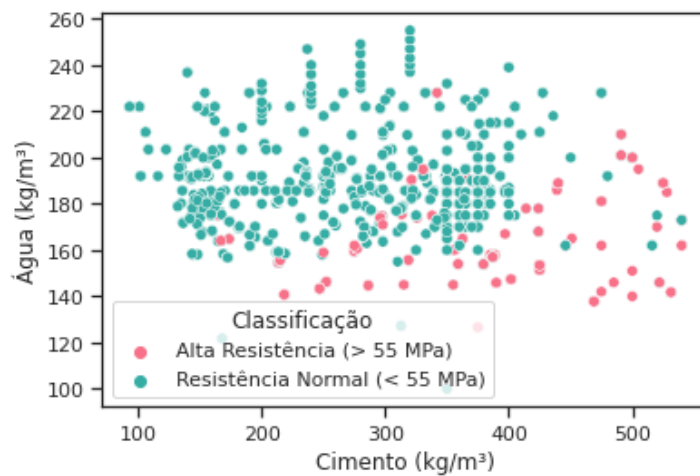
Apesar destas considerações, identificaram-se 3 instâncias com dosagens atípicas e isoladas do restante dos dados, e são excluídas. Estas foram com consumo de água superior a 275 kg/m^3 , consumo de agregado graúdo abaixo de 400 kg/m^3 , e de agregado miúdo acima de 1400 kg/m^3 .

Vale ressaltar que a metodologia deste trabalho adotou a escolha dos consumos de referência para cada material que constitui o traço de referência em massa a partir do percentil 50. Dessa forma, adotaram-se os consumos de 350 , 700 e 1050 kg/m^3 para o cimento, agregado miúdo e graúdo, respectivamente.

Na referência da seção sobre Concreto (seção 2.1), comentou-se que o presente trabalho parte da simplificação que concretos de resistência à compressão acima de 55 MPa seria considerado como de alta resistência e, assim, excluídos desta análise de concretos convencionais de resistência normal. A Figura 20 expõe um comparativo entre os consumos de cimento e água para o banco de dados criado, classificando-os pela resistência. Na Figura 20a

Verifica-se uma *cluster* de pontos vermelhos, com alto consumo de cimento e baixo consumo de água, o que leva a menores relações *a/c*. Dessa forma, é importante ressaltar que as análises de sensibilidade e usabilidade dos modelos devem respeitar o intervalo de 120 a 400 kg/m³ para o consumo de cimento, e 160 a 240 kg/m³ para o consumo de água, pois são os limites da nuvem de pontos verdes referentes aos concretos convencionais.

Figura 20 – Consumo de água e cimento para concretos de alta e normal resistências

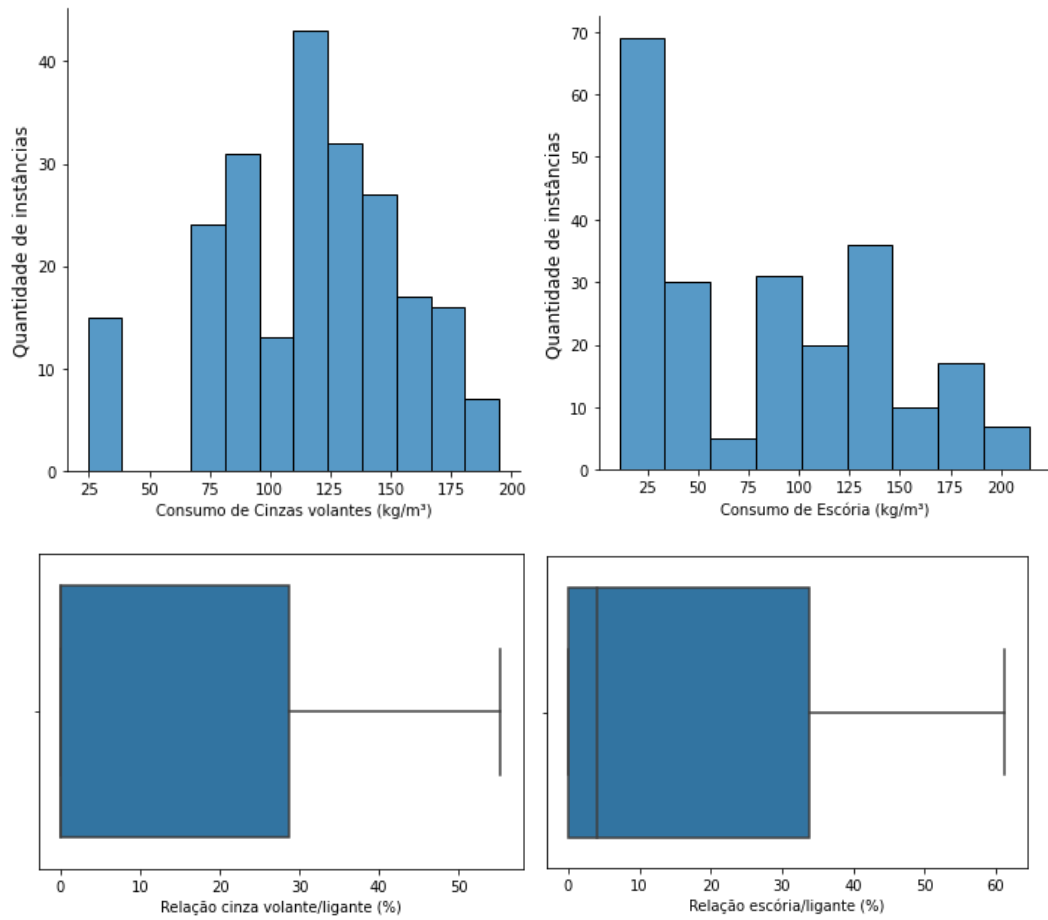


Fonte: elaborado pelo autor

As dosagens com adições cimentícias, isto é, cinza volante e escória granulada de alto forno, apresentam consumos de até 200 kg/m³ como exposto na Figura 21. Além disso, o percentil 75 do teor de cinza volante em relação ao ligante total da mistura é 29%, enquanto que para a escória é 33%. Dessa forma, a análise de sensibilidade e o uso do modelo como ferramenta de previsão devem respeitar o intervalo de consumo entre 0 e 200 kg/m³, e com a substituição do cimento pelas adições preferencialmente menores que 30%. Esses teores estão dentro dos limites estipulados pela ABNT NBR 16697:2018 para composição de cimentos CPIII.


Observa-se que a adição de cinza volante tende a piorar a resistência à compressão do concreto, mas não é um efeito tão significativo, pois a inclinação da reta de regressão não é tão acentuada, ver Figura 22. No caso da escória, não se observa uma tendência definida. Estas constatações estão de acordo com o comentado na seção sobre Resistência (seção 2.3.1) das referências, em que se observou que as adições podem contribuir para o aumento da resistência, mas a substituição do cimento nem sempre provoca este aumento.

Figura 21 – Análise descritiva do consumo de adições cimentícias nos concretos analisados do banco de dados de resistência



Fonte: elaborado pelo autor

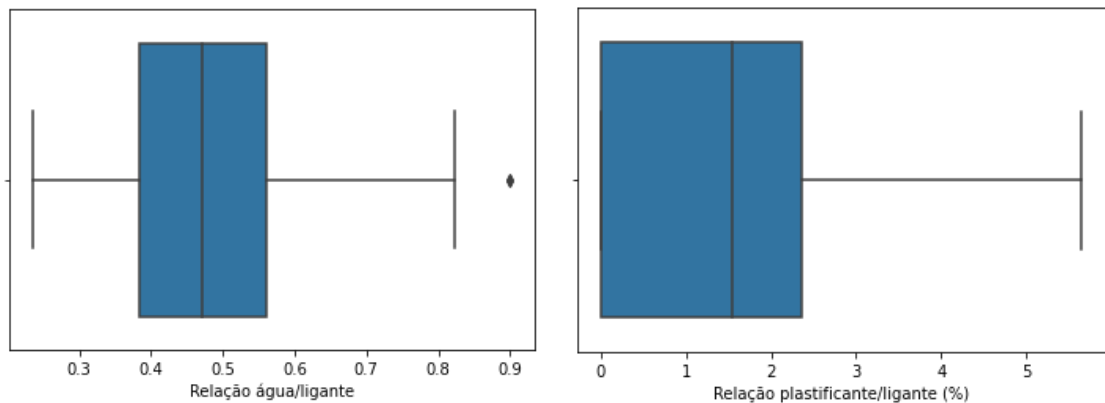
Figura 22 – Relação entre materiais cimentícios suplementares e a resistência



Fonte: elaborado pelo autor

Observa-se na Figura 23 que a relação entre água e o ligante está entre 0,20 e 0,82, e na maior parte das instâncias, entre 0,38 e 0,56, o que é um intervalo comum encontrado nas tabelas de classificação da ABNT NBR 12665:2006 para concretos adequados para diferentes classes de agressividade. Além disso, o consumo de plastificante em relação ao consumo total de ligante é sempre menor que 6%.

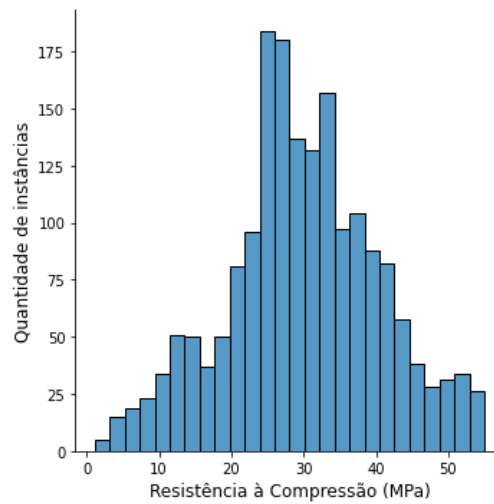
Figura 23 – Relações de água e plastificante com o ligante (cimento, cinza volante e escória) no banco de dados de resistência



Fonte: elaborado pelo autor

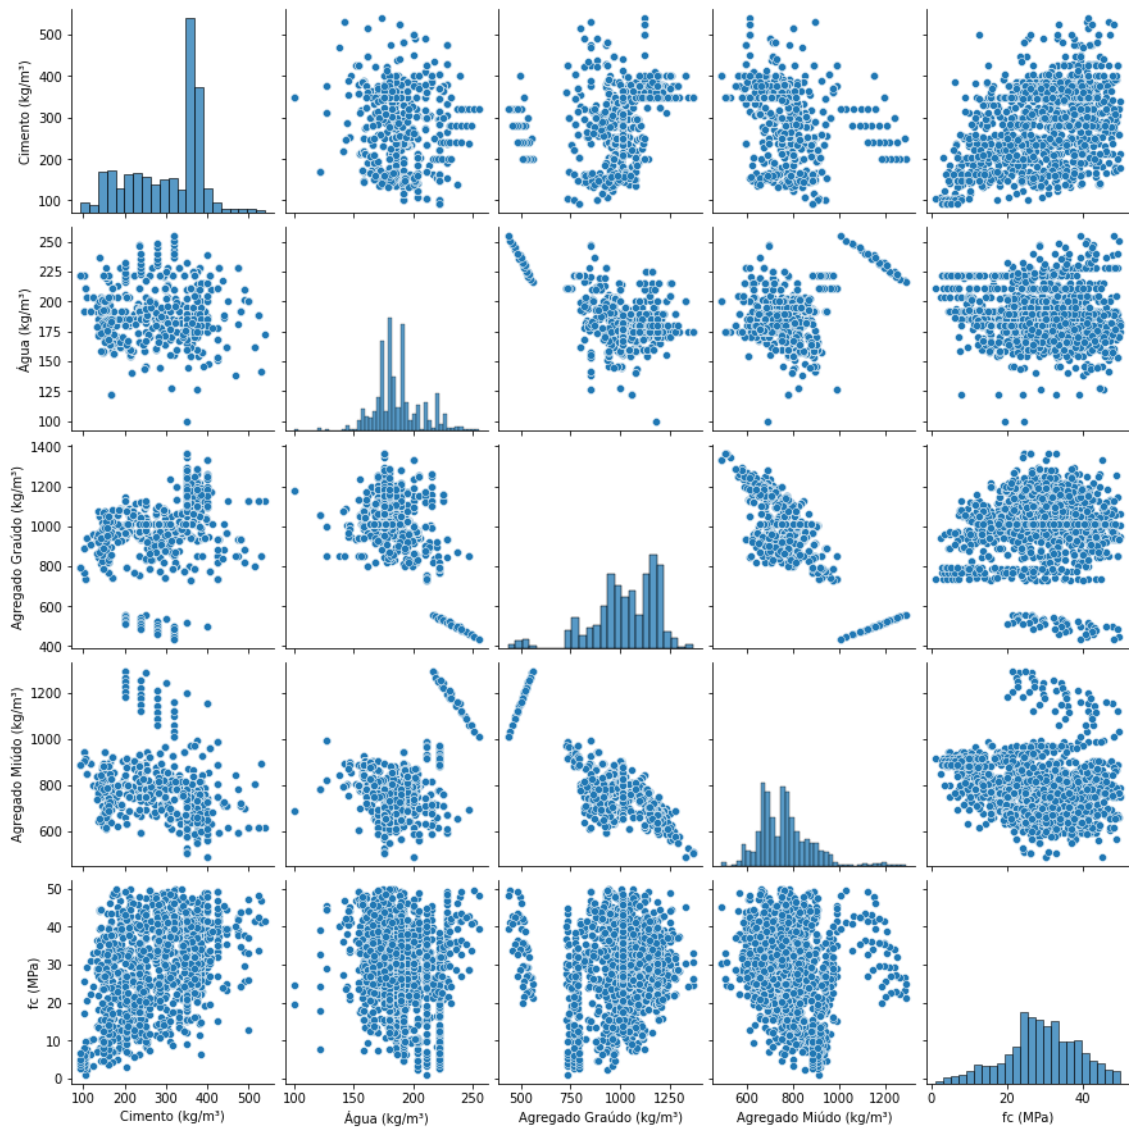
O histograma da Figura 24 apresenta a distribuição dos resultados de resistência à compressão. A maior parte das instâncias possuem resistência à compressão entre 20 e 40 MPa, mas também se observa valores mais baixos, próximos a 10 MPa, assim como valores próximos aos concretos de alta resistência (C60). Assim, espera-se que os modelos gerados consigam prever todas as classes de resistência do Grupo I da ABNT NBR 8953:2015 (C55, correspondente a 55MPa).

Figura 24 – Histograma de frequência absoluta da resistência à compressão




Fonte: elaborado pelo autor

A Figura 25 exibe *pairplots* entre consumo de cimento, água, agregados e a resistência à compressão. Constata-se um intervalo amplo para o consumo de cada material, o que é fator importante para o treino dos modelos. Identifica-se um *cluster* no consumo de agregados devido aos padrões de dosagem nos estudos comentados. Não se observa uma correlação forte entre as variáveis em estudo, pois a maioria dos *pairplots* mostram uma nuvem de pontos sem uma tendência clara. Contudo, percebe-se uma relação negativa entre o consumo de agregado graúdo e agregado miúdo, e uma correlação positiva entre o consumo de cimento e a resistência à compressão.

Figura 25 – *Pairplot* entre cimento, água, agregados e a resistência à compressão

Fonte: elaborado pelo autor

Figura 26 – *heatmap* das correlações entre o consumo de materiais, idade e resistência à compressão



Fonte: elaborado pelo autor

De acordo com o *heatmap* mostrado na Figura 26, verifica-se correlação positiva do consumo de cimento (0,33), plastificante (0,18) e a idade (0,35) com o f_c do concreto. Essas correlações estão de acordo com as referências da seção 2.3.1, pois o cimento é o material mais importante para o endurecimento da pasta, o plastificante é um agente redutor de água que pode diminuir a relação a/c e melhorar a resistência, e sabe-se que o f_c aumenta com a idade do concreto.

Observa-se correlação negativa com o consumo de água (-0,11), cinzas volantes (-0,2) e agregado miúdo (-0,13) com o f_c do concreto. Essas correlações também estão de acordo com o exposto nas referências, pois o aumento da quantidade água pode aumentar a relação a/c e diminuir a resistência, enquanto o uso de cinza volante pode prejudicar a resistência, principalmente nos primeiros dias.

Os consumos de escória e de agregado graúdo não mostraram uma relação direta com o f_c do concreto.

Analisando as correlações entre os demais atributos, observa-se uma alta correlação negativa entre o consumo de água e agregado graúdo (-0,53), e entre água e plastificante (-0,40). Alta correlação negativa entre consumo de cimento e os materiais cimentícios suplementares, o que é justificado pela sua substituição.

Apesar de se evitar o uso de variáveis auto correlacionadas nos modelos de aprendizagem de máquina, isso não foi procedido neste trabalho. Isso se deu por se tratar de variáveis importantes para explicar o fenômeno físico, além de não se observar nenhuma relação altamente positiva.

4.2 Banco de dados para previsão de abatimento

A Tabela 8 descreve a banco de dados para previsão de abatimento após a junção dos dados e o pré-tratamento de remoção de *outliers* e CAD de alta resistência realizadas no banco de dados de previsão de resistência. Um total de 784 instâncias são listadas, sendo 293 com adição de cinza volante, 103 com adição de escória e 230 com o uso de plastificante.

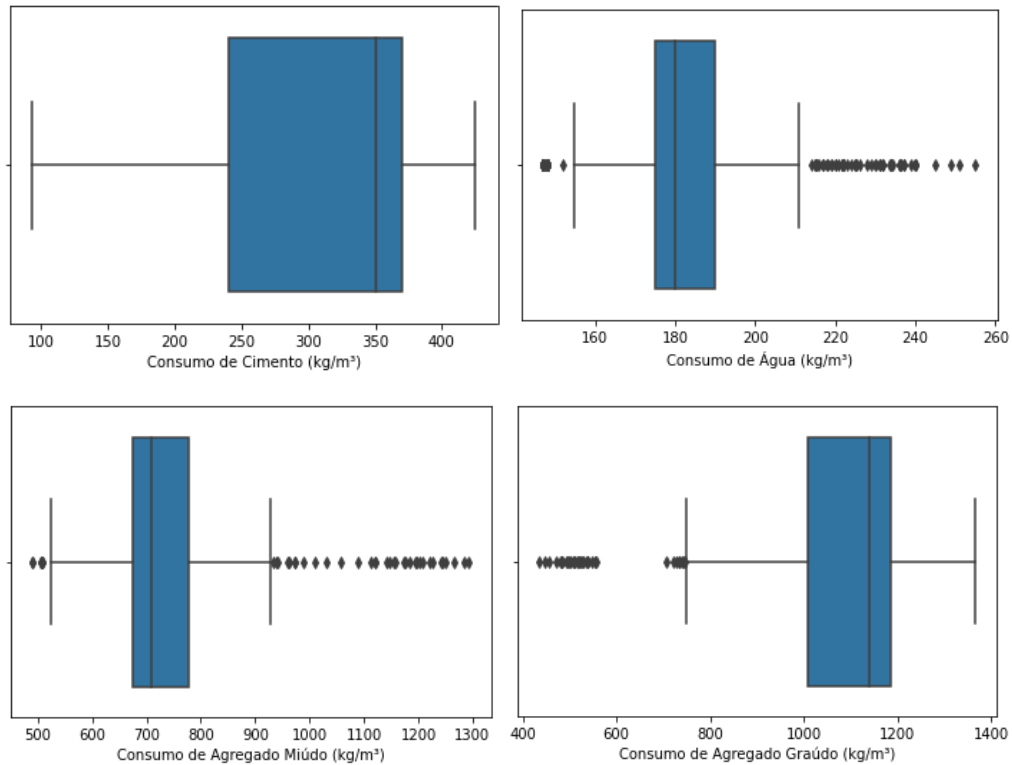
Tabela 8 – Banco de dados para previsão de abatimento de tronco de cone

	Consumo de cada material (kg/m ³)							Abatimento (mm)
	Cimento	Água	Agregado Miúdo	Agregado Graúdo	Cinza volante	Escória	Plastificante	
Qtd.	784	784	784	784	293	103	230	784
Mín.	93	147	490	436	0	0	2	0
Máx.	425	255	1293	1365	319	193	19	290
Média	308	183	738	1075	104	78	5	142
Desvio	84	20	113	166	71	60	4	53

Fonte: elaborado pelo autor

Inicialmente, verificou-se se o banco de dados possui *outliers* para o consumo de cada material, ver Figura 27. Identificou-se que os *outliers* para o consumo de cimento, água e agregados são os mesmos apontados pelos comentários da Figura 19. Concluiu-se que as instâncias adicionadas neste novo banco não se tratam de dosagens atípicas. Dessa forma, não é feito nenhum tratamento de remoção de *outliers*.


Figura 27 – *Boxplots* com dados de consumo de cimento, água e agregados no banco de dados de abatimento




Fonte: elaborado pelo autor

A adição de cinza volante é na maior parte entre 50 e 100 kg/m³, mas existe um bom número de instâncias de dosagens com adição de até 250 kg/m³, e não se observa uma tendência clara em mudar o abatimento pela reta de regressão da Figura 28. No caso da adição de escória, os intervalos mais usuais são entre 0 e 25 kg/m³, e entre 75 e 175 kg/m³. Observa-se que o uso escória pode causar uma perda de abatimento, evidenciado pela reta de regressão da Figura 28.

Figura 28 – Histograma e retas de regressão utilizados na análise descritiva do consumo de adições cimentícias (cinzas volantes e escórias) no banco de dados de abatimento






Fonte: elaborado pelo autor

Constata-se na Figura 29 que a quantidade de cinza volante em relação ao total de ligante é usualmente entre 23% e 42%, mas existem teores até 60%. Esses teores de cinza volante são maiores que o que foi encontrado para o banco de dados para previsão de resistência. Em relação ao consumo de escória, os teores são menores que 55%, e os valores mais usuais são abaixo de 29%. A adição de plastificante ocorre no intervalo de 1 a 4% do total de ligante.


Figura 29 – Relação entre materiais cimentícios e ligante (cimento, cinza volantes e escória) no banco de dados de abatimento



Fonte: elaborado pelo autor

Observa-se pela Figura 30 que as dosagens com maior teor de plastificante ocorrem para maiores consumos de cinza volante e escória. Esta alta correlação não é desejável no treino dos modelos, pois a dependências das variáveis de entrada prejudica a aprendizagem do modelo em explicar o abatimento em função de cada insumo. Por exemplo, o modelo pode entender que o consumo de escória melhora a consistência do concreto, sendo que ao usar somente a escória sem o plastificante, o efeito observado é o contrário.

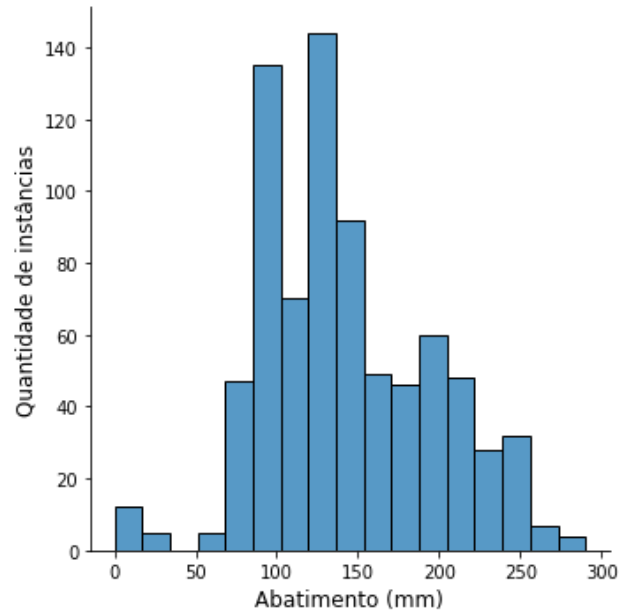
Figura 30 – Consumo de plastificante e de adições (cinzas volantes e escórias) no banco de dados de abatimento



Fonte: elaborado pelo autor


A distribuição de dados de abatimento é mais acentuada para valores entre 90 mm e 130 mm, mas há grande quantidade de dados com abatimento em torno de 150 mm. Considerando os intervalos restantes, instâncias de todas as classes de abatimento estão incluídas na análise, ver Figura 31.

Figura 31 – Histograma de densidade do abatimento



Fonte: elaborado pelo autor

Figura 32 – Heatmap das correlações entre o consumo de materiais e abatimento



Fonte: elaborado pelo autor

De acordo com o *heatmap* apresentado na Figura 32, verifica-se uma correlação positiva para o consumo de plastificante (0,33), agregado miúdo (0,25), cinzas volantes (0,43) e escória (0,11) com o abatimento. De acordo com o exposto na seção 2.3.2, o plastificante tem função de melhorar a trabalhabilidade de concreto, e concretos com cinza volante e escória pode também melhorar a consistência.

Observa-se uma correlação negativa para o consumo de cimento (-0,46) e para o agregado graúdo (-0,38) com o abatimento. Essas relações apresentam certo embasamento teórico, pois o consumo de mais cimento diminui o fator a/c em prol da resistência, e em detrimento da fluidez do concreto fresco (o cimento demanda água para fluir, pois tem alta superfície específica), além de que o consumo de agregado graúdo pode deixar o concreto no estado fresco com mais contatos entre grãos e, portanto, menos fluído.

Constata-se uma alta relação entre o consumo de cinzas volantes, escórias e plastificantes, como já foi evidenciado na Figura 30. Ademais, essas adições e o aditivo diminuem o consumo de cimento, fato destacado pelas correlações negativas. Não há necessidade de remover uma destas variável da análise, pois trata-se de variáveis importantes para explicar o fenômeno físico, além de não se observar nenhuma relação altamente positiva.

5 MODELAGEM PREDITIVA DOS DADOS

5.1 Modelo de classificação para previsão de resistência

Após a busca pelos hiperparâmetros ótimos, as melhores combinações encontradas pelo *GridSearchCV* foram:

- RNA com duas camadas intermediárias com 64 neurônios e a tangente hiperbólica como função de ativação;
- RF com 10 de profundidade máxima, 250 árvores na floresta e entropia como função de critério;
- SVM com C igual a 100, γ igual a 0,1 e base radial como função *kernel*.

Cada modelo foi avaliado pelo método de *5-fold Cross Validation*, computando-se o valor médio de acurácia, precisão, *recall* e *F1-score* para os 5 conjuntos de testes obtidos, ver Tabela 9.

Tabela 9- Comparativo entre os modelos de classificação para previsão de resistência

Modelo	Acurácia	Precisão	Recall	F1-score
RNA	0,52	0,52	0,50	0,51
RF	0,52	0,53	0,49	0,50
SVM	0,50	0,54	0,48	0,49

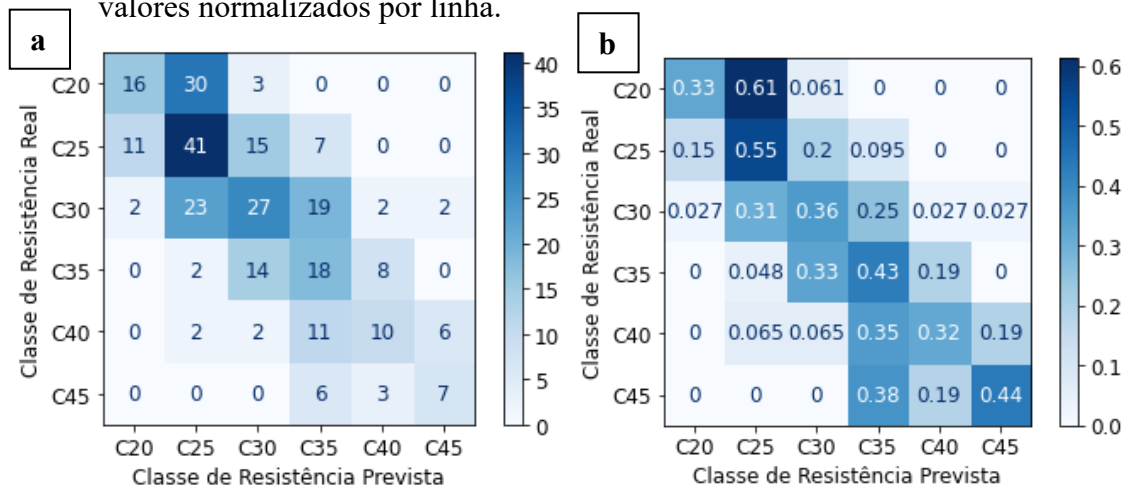
Fonte: elaborado pelo autor

Os modelos tiveram desempenhos bem semelhantes. O modelo RNA obteve maior valor de acurácia, *recall* e *F1-score*, e o SVM obteve a maior precisão. O modelo RNA é escolhido, pois teve melhores resultados no geral, e é treinado com o conjunto de dados de treino. Em seguida, verificou-se se o modelo tem uma boa capacidade de generalização, ao prever os dados do conjunto de teste.

A Figura 33 mostra os resultados com os dados de teste em uma matriz de confusão clássica e uma matriz de confusão com os valores normalizados por linha, usando a formulação do *recall* da Eq. 3. Observa-se que a maior parte das instâncias estão na região próxima a diagonal, o que é um bom indicador visual que as classificações estão próximas das corretas. Contudo, os valores da diagonal da matriz normalizada estão abaixo de 50%, com exceção da classe C25. Estes valores baixos, que representam o *recall* de cada classe, podem ser justificados pelo grande número de classes adotados. Além disso, estas classes representam

curtos intervalos de resistência, e concretos que diferem em 1 MPa podem pertencer a diferentes classes.


Figura 33 – Matrizes de confusão com resultados de previsão da classe de resistência: a) matriz de confusão clássica; b) matriz de confusão com os valores normalizados por linha.



Fonte: elaborado pelo autor

Uma outra forma de analisar o desempenho do modelo é considerar uma tolerância de uma classe na previsão. Assim, se o modelo prediz uma classe vizinha da correta, o resultado será um TP *tolerável*. Por exemplo, a classe C35 possui 18 TP, 14 FN classificados como C30 e 8 FN classificados como C40. Ao tolerar a predição errônea destas 22 instâncias FN por serem classes vizinhas, o número de TP tolerantes seria 40, o que aumentaria o *recall* para 95%. Analogamente, os *recalls* para as demais classes deste modelo com tolerância seriam: 94% para a C20; 90% para a C25; 92% para a C30; 86% para a C40; e 63% para a C45. Dessa forma, o *recall* médio é próximo de 90% para dados nunca vistos, o que evidencia uma boa performance do modelo, desde que se tolere o erro da estimativa inicial em uma classe de distância da classe alvo, ver Figura 33.


Figura 34 – Matriz de confusão com resultados de previsão da classe de resistência para o modelo tolerante



Fonte: elaborado pelo autor

FRANK e HALL (2001) apresentam um método que permite que algoritmos de classificação façam o uso de informações de ordenação em atributos de classe, e demonstram que o método supera o desempenho da abordagem clássica que trata as classes com um conjunto não ordenado. A Figura 34 mostra os resultados com esta abordagem. Observa-se que este modelo apresenta melhores previsões para as classes C25, C35 e C40 em relação a abordagem clássica, ver Figura 33a. Contudo, as classificações da classe C20 foram quase todas errôneas.

Figura 35 – Matriz de confusão com resultados de previsão da classe de resistência para com a técnica de classificação ordinal



Fonte: elaborado pelo autor

5.1.1 Interpretação do modelo

O modelo de classificação pode ser usado como uma ferramenta para estimar um traço inicial que atenda um requerimento de resistência. Um caso de aplicação é estimar o quanto de cimento se deve adicionar ao traço de referência para aumentar uma classe de resistência. De acordo com a Tabela 10, basta aumentar o consumo de cimento de 350 kg/m³ para 375 kg/m³. Caso deseje-se uma classe C40, o consumo deve subir para 385 kg/m³, para o qual alcança-se um f_c maior que 40 MPa. Verifica-se que mudando apenas a quantidade de cimento na mistura, não se atinge concretos de classe C45.

Tabela 10- Classes de resistência para intervalos de consumo de cimento

Classe Prevista	Consumo de Cimento (kg/m ³)	
	Inferior	Superior
SEM CLASSE	150	250
C20	250	255
C25	255	325
C30	325	375
C35	375	385
C40	385	500

Fonte: elaborado pelo autor

A Tabela 11 indica como as classes variam para diferentes fatores a/c . Nota-se que para relações inferiores a 0,42, situam-se os concretos de classe C40, e para relações superiores a 0,69, encontram-se os concretos sem classificação, isto é, cujo resistência à compressão é inferior à 20 MPa.

Tabela 11- Classes de resistência para intervalos de fatores a/c

Classe Prevista	Fator a/c	
	Inferior	Superior
SEM CLASSE	0,69	0,80
C20	0,68	0,69
C25	0,53	0,68
C30	0,44	0,53
C35	0,42	0,44
C40	0,30	0,42

Fonte: elaborado pelo autor

Em relação ao agregado graúdo, identifica-se um padrão mais complexo, pois a classe nem sempre aumenta com o aumento do consumo do agregado, ver Tabela 12. Em linhas gerais, para consumos inferiores a 1030 kg/m³, o concreto é classificado como C40 ou C45, enquanto que para consumos superiores a 1080 kg/m³, o concreto é classificado como C20 ou C25.

Tabela 12- Classes de resistência para intervalos de consumo de agregado graúdo

Classe Prevista	Consumo de Ag. Graúdo (kg/m ³)	
	Inferior	Superior
C20	1200	1400
C25	1080	1200
C30	1030	1080
C40	700	870
C45	870	1030

Fonte: elaborado pelo autor

No que concerne ao agregado miúdo, observou-se que para consumos superiores a 900 kg/m³, a classe de resistência tende a diminuir, até chegar em concretos sem classe para consumos superiores a 1080 kg/m³, ver Tabela 13.

Tabela 13- Classes de resistência para intervalos de consumo de agregado miúdo

Classe Prevista	Consumo Ag. Miúdo (kg/m ³)	
	Inferior	Superior
SEM CLASSE	1080	1200
C20	1030	1080
C25	900	1030
C30	600	720
C35	720	900

Fonte: elaborado pelo autor

De modo geral, o modelo de classificação está de acordo com as constatações de HELENE e TERZIAN (1993) apresentadas na Tabela 3, pois a resistência prevista pelo modelo tende a aumentar com o consumo de cimento, com a redução da relação a/c , e aumento da relação entre agregado graúdo e miúdo. Contudo, a previsão das classes de resistência a partir da variação do consumo de cada tipo de agregado não mostrou uma tendência clara. Assim como explicado na seção sobre Resistência (seção 2.3.1), a literatura consultada aponta diversos

fatores importantes sobre os agregados que explicam a resistência e que não foram considerados neste modelo de classificação, tais como natureza, forma, textura e dimensão dos grãos.

5.2 Modelo de Regressão Para Previsão de Resistência

Após a busca pelos hiperparâmetros ótimos, as melhores combinações encontradas pelo *GridSearchCV* foram:

- a) RNA com duas camadas intermediárias com 64 neurônios em cada e tangente hiperbólica como função de ativação em cada camada.
- b) RF com 25 de máxima profundidade, 250 árvores na floresta e erro quadrático como função de critério;
- c) SVM com C igual a 50, γ igual a 0,1 e base radial como a função *kernel*.

Cada modelo foi avaliado pelo método de *5-fold Cross Validation*, computando-se o valor médio de RMSE e MAE para os 5 conjuntos de testes obtidos, ver Tabela 14.

Tabela 14- Comparativo entre modelos de regressão para previsão de resistência


Modelos	RMSE (MPa)	MAE (MPa)
RNA	4,19	2,99
RF	4,38	3,23
SVM	4,73	3,45

Fonte: elaborado pelo autor

O modelo RNA obteve melhor desempenho para os dois parâmetros e é escolhido com modelo de regressão principal para previsão de resistência. O MAE de 2,99 MPa é aceitável, pois em aplicações da construção civil, uma variação próxima a 3 MPa para determinar a resistência de um traço de partida para dosagem é usual na prática. Percebe-se que o SVM foi mais sensível a *outliers*, pois o RMSE foi de 4,73 MPa, além de deter o maior MAE de 3,45. Vale ressaltar que os valores de RMSE e MAE estão relativamente próximos, o que indica a presença de poucos *outliers* nas previsões.

O modelo RNA é treinado e então procura-se averiguar a sua capacidade de prever os dados separados para teste. A Figura 36 mostra o resultado para a previsão do conjunto de teste. Neste treino final, observa-se bons resultados, com um alto coeficiente de correlação R^2 igual a 0,796, além de RMSE e MAE próximos ao encontrados no *5-fold Cross Validation*.

Figura 36 – Gráfico com valores previstos pelo modelo de regressão comparados aos valores reais de resistência



Fonte: elaborado pelo autor

5.2.1 Interpretação do Modelo

A Figura 37 apresenta as curvas PDP e ICE para cada variável de entrada do modelo, a partir das quais se consegue identificar quais as variáveis explicam melhor as previsões de resistência. Ambas as curvas têm inclinações positivas para o consumo de cimento e a idade do concreto, o que indica uma correlação entre essas variáveis e a resistência. No caso do cimento, as curvas possuem uma inclinação praticamente constante, enquanto que, para a idade, as curvas são bem mais acentuadas nos primeiros dias.

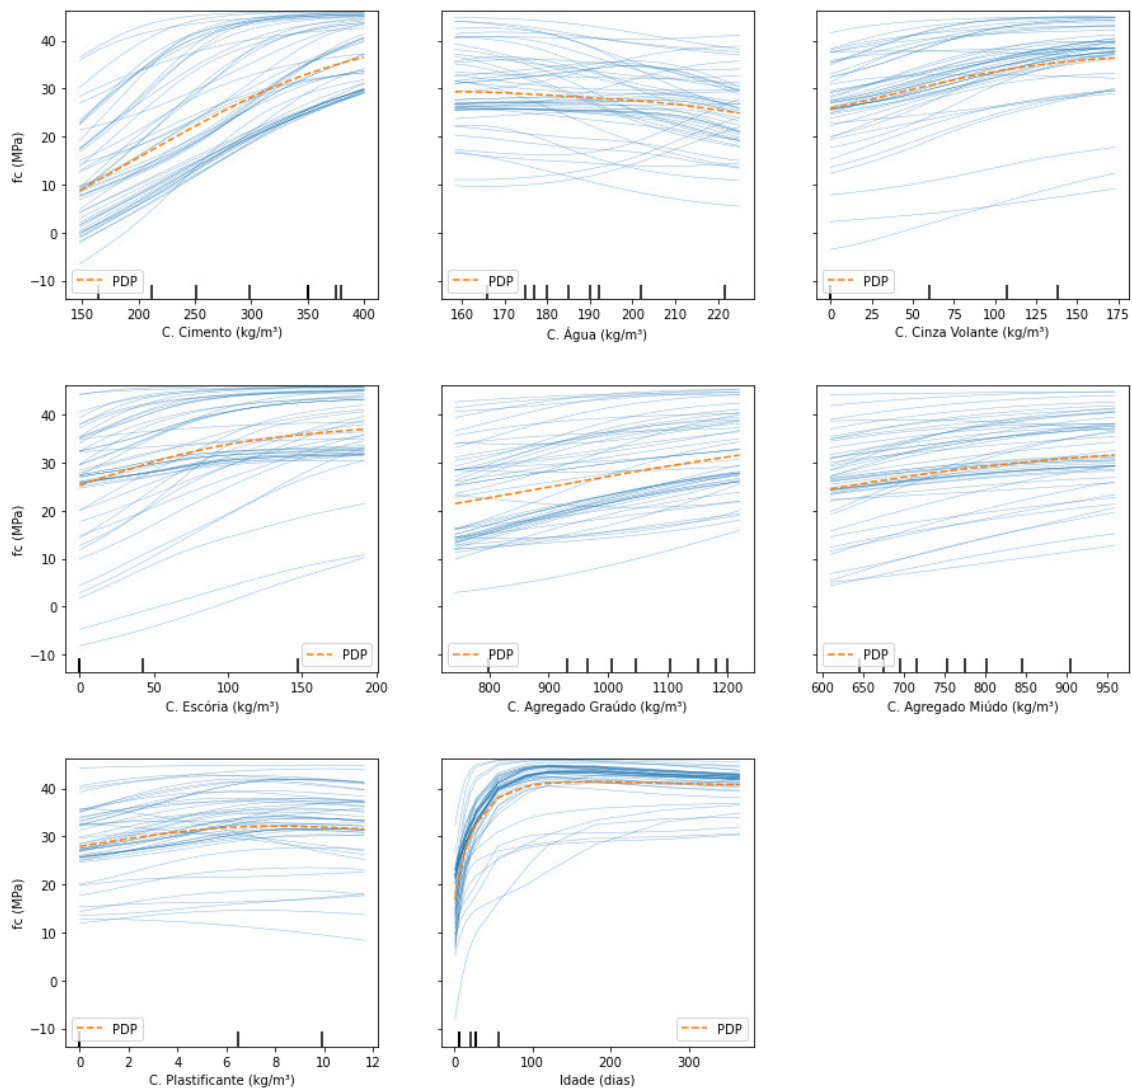
A curva PDP do consumo de água é a única com relação negativa. Contudo, observa-se curvas ICE para casos em que o aumento do consumo de água melhora a resistência. De fato, concretos formados com mais pasta necessitam de mais água, e a resistência final é maior.

A adição de cinza volante e escória tendem a aumentar a resistência do concreto, pois observou-se que a maior parte das curvas ICE tem inclinação positiva.

Constata-se que o aumento do consumo de grãos graúdos melhora consideravelmente a resistência, evidenciado pela PDP com inclinação positiva, enquanto que o aumento do consumo de agregados finos não impacta tanto na resistência, pois a curva PDP possui uma inclinação bem suave, apesar de positiva.

Vale ressaltar que existem valores negativos de resistência nos gráficos plotados, pois o modelo pode ser avaliado com dados irrealis, como concretos formados sem cimento. Mais detalhes sobre isso foram apresentados na seção sobre PDP e ICE (seção 3.1.8.1), e isso será retomado nas análises de sensibilidade dos modelos.


Figura 37 – Gráficos de PDP e ICE para cada variável de entrada do modelo de previsão de resistência



Fonte: Elaborado pelo autor

A Figura 38 mostra uma curva ICE considerando consumo de água e cimento. Observa-se que um alto consumo de cimento no intervalo de 350 kg/m^3 a 400 kg/m^3 gera concretos mais resistentes, com f_c próximo a 35 MPa , enquanto que diminuir o consumo forma concretos cada vez menos resistentes, atingindo valores abaixo de 10 MPa . A seta em azul mostra que para consumos fixados de cimento, diminuir a quantidade de água melhora a resistência. Essas constatações estão de acordo com a lei de Abrams (ABRAMS, 1919).


Figura 38 – Gráfico PDP entre resistência e consumos de cimento e água



Fonte: elaborado pelo autor

A Figura 39 mostra uma região de alta resistência para um baixo consumo de água aliado ao uso de muito plastificante, evidenciando a sua função redutora de água, o que forma concretos com menor fator a/c e mais resistentes (KOSMATKA; PANARESE; KERKHOFF, 2002). Além disso, observa-se três regiões de baixa resistência destacadas na figura, o que indica a importância de estudar previamente a dosagem do plastificante para evitar situações que a resistência tende a diminuir consideravelmente. Essas regiões ocorrem nos casos extremos com alto e baixo consumo de água e plastificante.

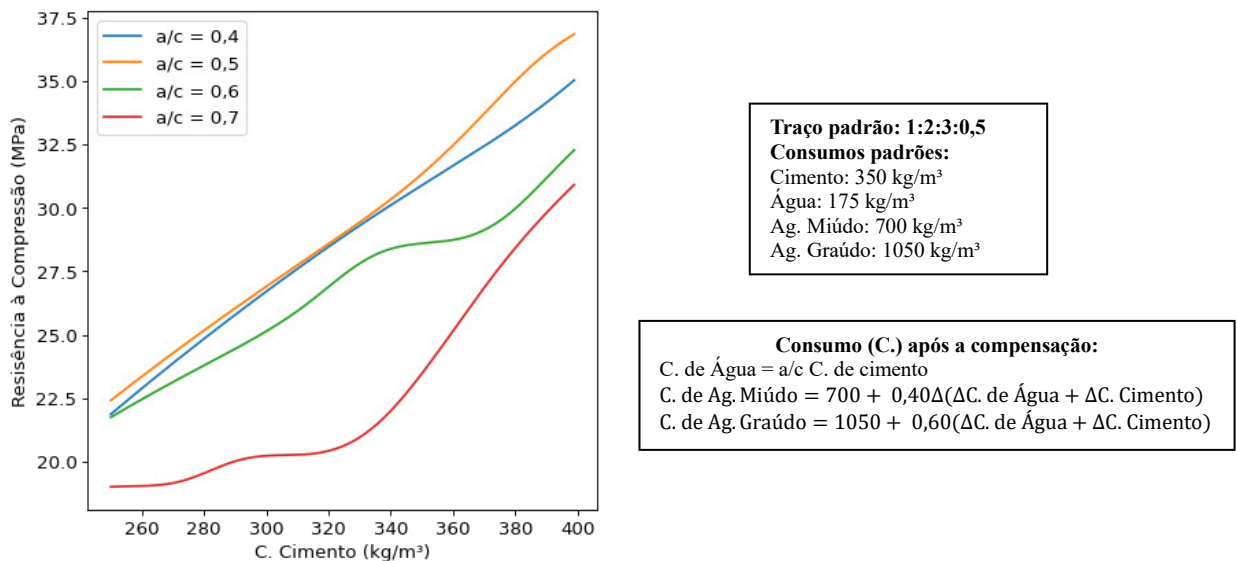
Figura 39 – Gráfico PDP entre resistência e consumos de plastificante e água



Fonte: elaborado pelo autor

A Figura 40 expõe como a relação a/c impacta na resistência do concreto. A tendência observada é que altos fatores a/c geram concretos menos resistentes, como apontado pela curva vermelha com a/c igual a 0,7 que atinge resistências menores que 20 MPa. A curva verde com a/c igual a 0,6 já mostra um crescimento considerável na resistência, alcançando resistências acima de 30 MPa. As outras duas curvas mostram f_c próximos todo o intervalo e maiores que as curvas mencionadas.


Figura 40 – Relação entre resistência e o consumo de cimento para diferentes fatores a/c , considerando a compensação de volume nas substituições



Fonte: elaborado pelo autor

A Figura 41 elucida o efeito da relação a/c em outra perspectiva. As curvas encontradas se assemelham à curva apresentada por OLIVEIRA (2004), onde se identificam dois padrões: ramo de concreto seco e outro ramo de concreto plástico (cf. Figura 1). Neste ramo, não é a presença da água sozinha que permite o adensamento, mas são necessárias maiores energias para adensar o concreto, sendo a energia de compactação uma variável importante, e não incluída na análise. O concreto seco, também chamado de concreto sem abatimento, é caracterizado pelo baixo consumo de água que os concretos usuais. OLIVEIRA (2004) comenta que para concretos muito secos, o acréscimo de água melhora consideravelmente a trabalhabilidade da mistura, diminuindo o atrito interno entre os grãos, o que facilita a compactação. Isto é, fixado um traço e energia de compactação, aumentar o consumo de água implica diminuir a porosidade total, o que melhora a resistência do concreto. Em contrapartida, concretos do ramo plástico seguem a “lei” de ABRAMS (1919).

Figura 41 – Relação entre a resistência e o fator a/c para diferentes consumos de cimento, considerando a compensação de volume nas substituições




Fonte: elaborado pelo autor

A substituição do cimento por outros materiais cimentícios é estudada na Figura 42 e na Figura 43. No caso da cinza volante, verifica-se que para menores quantidades de ligante (cimento e adições), a substituição do cimento provoca uma perda de resistência considerável, indicado pela curva azul. Para maiores consumos de ligante, a substituição não afeta tanto a resistência, como pode ser observado pelas curvas vermelha e verde. Um padrão semelhante é identificado para substituição de cimento por escória, contudo a queda da resistência é mais perceptível. Essas constatações estão de acordo com o exposto na seção 2.3.1 da referência, onde as adições cimentícias contribuem para aumentar a resistência, mas a substituição do cimento pode prejudicar a resistência, principalmente nos primeiros dias, devido às reações lentas dos materiais pozolânicos (KOSMATKA; PANARESE; KERKHOFF, 2002). Sublinha-se, porém, que essas adições podem contribuir para ganhos de resistência em idades mais avançadas, como foi exposto na seção sobre Resistência (seção 2.3.1).


É interessante ressaltar que as curvas PDP para estes materiais mostram uma relação positiva com a resistência, enquanto que a análise paramétrica com substituição do cimento mostra um efeito contrário, pois o cimento é um material mais importante para explicar a resistência do concreto. Isso indica ainda mais a importância da compensação de volume nessas substituições nas análises de sensibilidade aqui incluídas.

Figura 42 – Relação entre a resistência e o consumo de cinza volante para diferentes consumos de ligante, considerando a substituição do cimento por cinza volante



Fonte: elaborado pelo autor


Figura 43 – Relação entre a resistência e o consumo de escória para diferentes consumos de ligante, considerando a substituição do cimento por escória



Fonte: elaborado pelo autor

A Figura 44 mostra que o acréscimo de agregado miúdo na mistura tende a aumentar a resistência. Esse efeito é mais perceptível na curva azul com consumo de 250 kg/m³, e mitigado conforme o consumo de cimento aumenta.


Figura 44 – Relação entre a resistência e o consumo de agregado miúdo para diferentes consumos de cimento, considerando a compensação de volume nas substituições



Fonte: elaborado pelo autor

Um padrão oposto pode ser observado na Figura 45, onde o acréscimo de agregado graúdo tende a diminuir a resistência. Este efeito é mais perceptível na curva vermelha com consumo de 400 kg/m³ e tende a ser menor conforme o consumo de cimento diminui. Vale ressaltar que as dosagens na Figura 45 geram concretos consistentemente mais resistentes que as dosagens da Figura 44.

Figura 45 – Relação entre a resistência e o consumo de agregado graúdo para diferentes consumos de cimento, considerando a compensação de volume nas substituições



Traço padrão: 1:2:3:0,5

Consumos padrões:

Cimento: 350 kg/m³

Água: 175 kg/m³

Ag. Miúdo: 700 kg/m³

Ag. Graúdo: 1050 kg/m³

Consumo (C.) dos materiais restantes

$\Delta C.$ de Água = 0,03 Δ Consumo de Ag. Graúdo

$\Delta C.$ de Ag. Miúdo = 0,88 $\Delta C.$ de Ag. Graúdo

Em relação ao consumo de cimento fixado:


$\Delta C.$ de Água = 0,03 $\Delta C.$ de Cimento

$\Delta C.$ de Ag. Miúdo = 0,75 $\Delta C.$ de Cimento

Fonte: elaborado pelo autor

A Figura 46 mostra o efeito direto da adição de agregado graúdo sem a análise paramétrica, e verifica-se que concretos mais pesados tendem a ter maior resistência. Analogamente ao comentado para as adições cimentícias, a curva PDP do agregado graúdo mostra uma forte relação positiva com a resistência, mas a substituição por outros materiais pode provocar o efeito contrário. A Figura 46 também está de acordo com o exposto na seção sobre Trabalhabilidade (seção 2.3.2), em que aumentar a relação de agregado graúdo por miúdo tende a melhorar a resistência (HELENE; TERZIAN, 1993).

Figura 46 – Relação entre a resistência e o consumo de agregado graúdo para diferentes consumos de agregado miúdo



Fonte: elaborado pelo autor

5.3 Modelo de classificação para previsão de abatimento

Após a busca pelos hiperparâmetros ótimos, as melhores combinações encontradas pelo *GridSearchCV* foram:

- RNA com uma camada intermediária com 100 neurônios e *relu* como função de ativação;
- RF com 100 de profundidade máxima, 250 árvores na floresta e entropia como função de critério;
- SVM com *C* igual a 5, *gamma* igual a 1, e base radial como função *kernel*.

Cada modelo foi avaliado pelo método de *5-fold Cross Validation*, computando-se a média de acurácia, precisão, *recall* e *F1-score* para os 5 conjuntos de testes obtidos, ver Tabela 15.

Tabela 15- Comparativo entre modelos de classificação para previsão de abatimento


Modelo	Acurácia	Precisão	Recall	F1-score
RNA	0,75	0,75	0,64	0,64
RF	0,76	0,73	0,68	0,69
SVM	0,76	0,80	0,65	0,66

Fonte: elaborado pelo autor

Os modelos tiveram desempenhos bem semelhantes. O modelo RF apresentou maiores valores de *recall* e *F1-score*, enquanto o SVM maior precisão. Optou-se pela escolha do modelo SVM após investigar que as análises de sensibilidade eram mais condizentes com a literatura, como será mostrado na próxima seção.

O modelo SVM é treinado e verifica-se seu desempenho com os dados de teste. A matriz de confusão é mostrada na Figura 47, e percebe-se que apesar da alta acurácia média de 80%, existe uma forte tendência em classificar as instâncias como S100. Isto pode ser constatado pelos 17 FP da classe S50, e os 5 FP da classe S160. Dessa forma, o modelo não está bem treinado para prever concretos com baixo ou alto abatimento.


Figura 47 – Matriz de confusão com resultados de previsão da classe de abatimento



Fonte: elaborado pelo autor

Observa-se que as classes S10, S50 e S220 possuem poucos dados comparados com as classes S100 e S160. Este é um problema usual em modelos de classificação, denominado classificação desbalanceada (do inglês, *imbalanced classification*). Uma forma de melhorar o desempenho na previsão das classes com poucos dados é aplicar técnicas de subamostragem (do inglês, *undersampling*). LEMAÎTRE, NOGUEIRA e ARIDAS (2017) desenvolveram um algoritmo de subamostragem que consiste em remover instâncias do conjunto de dados de treino que pertencem às classes majoritárias. Dessa forma, equilibra-se melhor a distribuição de dados para cada classes, e os erros de previsão da classe minoritária são mais penalizados do que antes. A Figura 48 mostra a matriz de confusão para o modelo treinado com a técnica de subamostragem (LEMAÎTRE; NOGUEIRA; ARIDAS, 2017).

Figura 48 – Matriz de confusão com resultados de previsão da classe de abatimento usando a técnica de subamostragem




Fonte: elaborado pelo autor

Observa-se que para este modelo, as classificações das classes minoritárias são acertadas na maioria dos casos, porém, o modelo perde capacidade de acerto na classe majoritária S100.

A Figura 49 mostra os resultados da abordagem de classificação ordinal (FRANK; HALL, 2001) já comentada na seção sobre classificação de resistência (seção 5.1). Observa-se que os valores encontrados na matriz são próximos à abordagem clássica, ver Figura 47.

Figura 49 – Matriz de confusão com resultados de previsão da classe de abatimento usando técnica de classificação ordinal



Fonte: elaborado pelo autor

5.3.1 Interpretação do Modelo

O modelo de classificação pode ser usado como uma ferramenta para estimar um traço inicial que atenda a um requisito de abatimento. Um caso de aplicação é estimar o quanto de água deve-se adicionar ao traço de referência para aumentar uma classe de abatimento. De acordo com a Tabela 16, basta aumentar o consumo de 175 kg/m³ para 225 kg/m³. Caso deseje-se um concreto de classe S220, deve-se aumentar o consumo para 230 kg/m³.

Tabela 16- Classes de abatimento para intervalos de consumo de água

Classe Prevista	Consumo de Água (kg/m ³)	
	Inferior	Superior
S50	155	165
S100	165	225
S160	225	230
S220	230	240

Fonte: elaborado pelo autor

É interessante comparar estes resultados com o quadro de dosagem construído a partir do método de dosagem ABCP/ACI. Neste método, a determinação do consumo de água depende da dimensão máxima do agregado graúdo, variável que não foi considerada no presente trabalho. Na Tabela 16, observa-se que abatimentos entre 50 e 100 mm são encontrados para consumos de água no intervalo de 165 a 225 kg/m³, enquanto que pelo método ABCP/ACI, o consumo de água varia entre 185 a 230 kg/m³ para essa faixa de abatimento, ver Tabela 17. Percebe-se que os intervalos estão próximos, o que um fator positivo na validação da ferramenta.

Tabela 17- Consumo de água aproximado para diferentes intervalos de abatimento pelo método ABCP/ACI

Abatimento (mm)	Consumo de água aproximado (l/m ³)				
	D _{máx} agregado graúdo (mm)				
	9,5	19,0	25,0	32,0	38,0
40 a 60	220	195	190	185	180
60 a 80	225	200	195	190	185
80 a 100	230	205	200	195	190

Fonte: ABCP (1984)

Outra forma de melhorar a consistência do concreto fresco é pela adição de plastificante. De acordo com a Tabela 18, bastaria adicionar 3,8 kg/m³ de plastificante para aumentar uma classe partindo da classe S100, e 4,4 kg/m³ para atingir na classe S220.

Tabela 18- Classes de abatimento para intervalos de consumo de plastificante

Classe Prevista	Consumo de Plastificante (kg/m ³)	
	Inferior	Superior
S100	0	3,8
S160	3,8	4,4
S220	4,4	8

Fonte: elaborado pelo autor

O modelo não se mostrou sensível à mudanças no consumo de cimento. Para todo o intervalo de estudo, a classe prevista foi a S100. Assim, o consumo de cimento não explica bem o resultado de abatimento, e existem outras variáveis mais importantes. A literatura costuma sublinhar a importância do consumo de água para o abatimento.

Tabela 19- Classes de abatimento para intervalos de consumo de cimento

Classe Prevista	Consumo de Cimento (kg/m ³)	
	Inferior	Superior
S100	250	450

Fonte: elaborado pelo autor

Em relação aos agregados, constata-se que aumentar a quantidade de agregados miúdos aumenta a classe de abatimento, enquanto que aumentar a quantidade de agregados graúdos diminui a classe de abatimento, como pode ser observado pela Tabela 20 e pela Tabela 21. Esses resultados estão de acordo com o exposto na seção sobre Trabalhabilidade (seção 2.3.2), em que aumentar a relação de agregado miúdo por graúdo tende a aumentar o abatimento (HELENE; TERZIAN, 1993).

Tabela 20- Classes de abatimento para intervalos de consumo de agregado miúdo

Classe Prevista	Consumo de Ag. Miúdo (kg/m ³)	
	Inferior	Superior
S100	500	710
S160	710	950
S220	950	1000

Fonte: elaborado pelo autor

Tabela 21- Classes de abatimento para intervalos de consumo de agregado graúdo

Classe Prevista	Consumo de Ag. Graúdo (kg/m³)	
	Inferior	Superior
S100	1000	1300
S160	780	1000
S220	700	780

Fonte: elaborado pelo autor

5.4 Modelo de Regressão Para Previsão de Abatimento

Após a busca pelos hiperparâmetros ótimos, as melhores combinações encontradas pelo *GridSearchCV* foram:

- a) RNA com duas camadas intermediárias com 64 neurônios em cada e *relu* como função de ativação em cada;
- b) RF com 100 de máxima profundidade, 50 árvores na floresta e erro quadrático como função de critério;
- c) SVM com *C* igual a 100, *gamma* igual a 0,1 e sendo a base radial *como* a função *kernel*.

Os modelos foram avaliados pelo método de *5-fold Cross Validation*, computando-se o valor médio de RMSE e MAE para os 5 conjuntos de testes obtidos, ver Tabela 22.

Tabela 22- Comparativo entre modelos de regressão para previsão de abatimento


Modelos	RMSE (mm)	MAE (mm)
RNA	37,66	25,97
RF	39,16	25,78
SVM	38,24	25,47

Fonte: elaborado pelo autor

Os três modelos tiveram desempenho bem semelhante. O SVM obteve menor MAE, enquanto o RNA apresentou o melhor RMSE, mas os valores estão próximos. O MAE próximo de 26 mm é aceitável para um traço inicial, visto que aplicações para uma determinada classe de consistência admite um intervalo considerável para o abatimento. Por exemplo, a classe S160 detém o intervalo de abatimentos entre 160 e 220 mm. O modelo RNA foi escolhido como modelo principal na previsão de resistência, pois ele se mostrou mais consistente com a literatura na interpretação mostrada na seção a seguir. As curvas geradas são contínuas e mostram tendências mais definidas que as encontradas para os outros dois modelos.

Com o modelo RNA treinado, procurou-se averiguar a sua capacidade de generalização para prever o conjunto de dados nunca visto. A Figura 50 mostra os resultados de previsão para os dados de teste. Observam-se bons resultados, com coeficiente de determinação R^2 de 0,692, além de RMSE e MAE próximos ao encontrados no *5-fold Cross Validation*.

Figura 50 – Gráfico com valores previstos pelo modelo de regressão



Fonte: elaborado pelo autor

O desempenho na previsão de abatimento é inferior a observada no modelo de previsão de resistência. Isto pode ser explicado pelo menor número de dados usados para treino e validação, além de outras possíveis variáveis de entrada do modelo que podem explicar melhor o comportamento reológico do concreto fresco e não foram consideradas. Entre eles, fatores como a composição química do cimento, as características físicas dos agregados, e o tipo de interação entre elas, a temperatura, e teor de ar incorporado podem ser mencionados (DE CASTRO; LIBORIO; PANDOLFELLI, 2011; ROUSSEL, 2011).

5.4.1 *Interpretação do Modelo*

Figura 51 apresenta os gráficos PDP e ICE para cada variável de entrada do modelo, a partir das quais se consegue identificar quais as variáveis explicam melhor as previsões de abatimento.

A curva PDP de consumo cimento tem forte inclinação negativa, indicando que o aumento do consumo de cimento piora a consistência do concreto fresco.

A curva PDP do consumo de água mostra uma relação positiva com o abatimento, mas identificam-se diferentes padrões para as curvas ICE, o que implica uma maior complexidade em explicar o abatimento pela quantidade de água no sistema. Por exemplo, boa parte das curvas ICE possuem dois pontos de mínimo de abatimento, para consumos de 170 e 210 kg/m³.

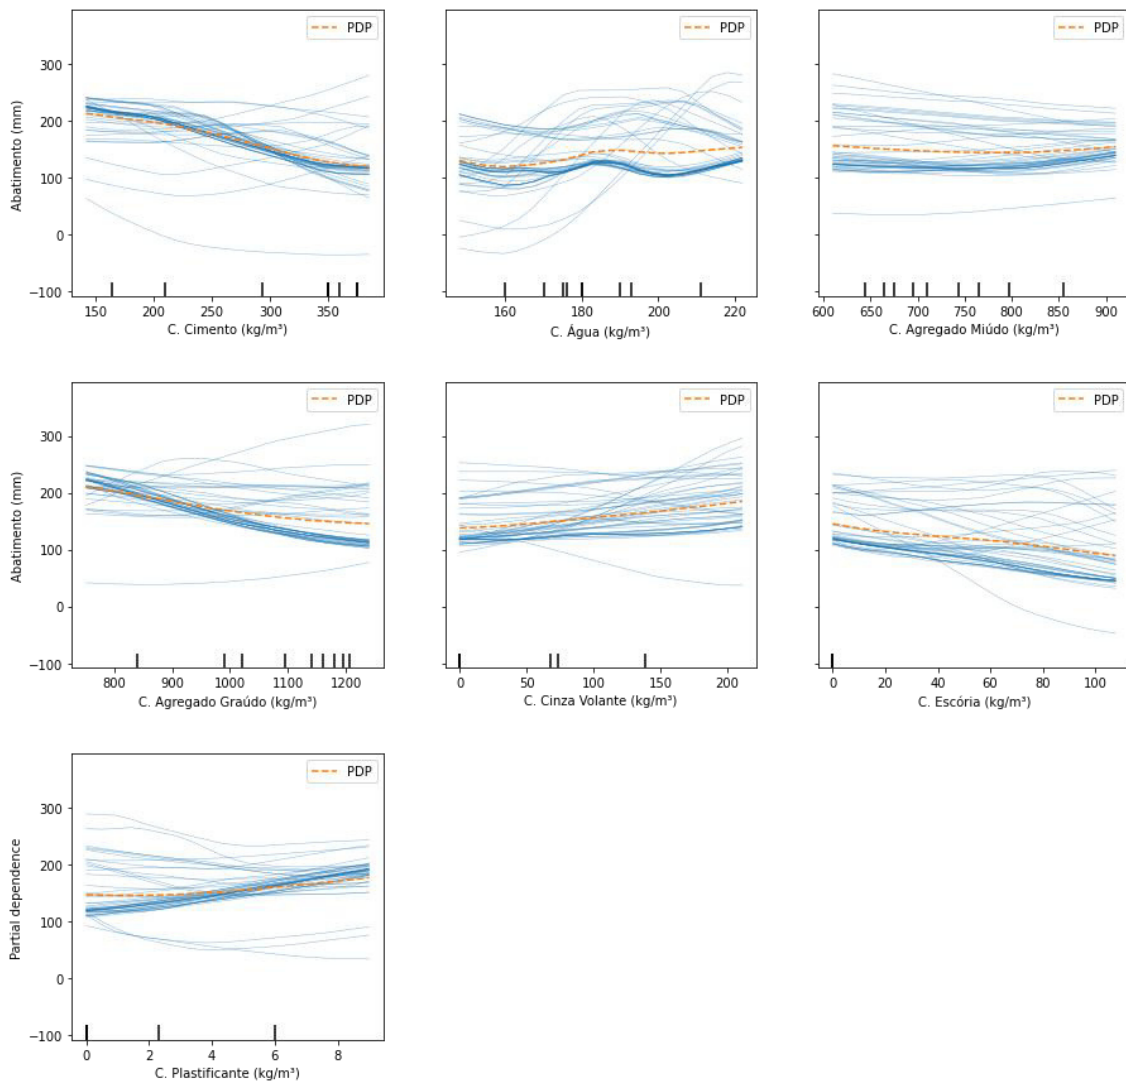
A maioria das curvas para o agregado miúdo apresentam inclinações nulas, e assim o abatimento não é bem explicado pelo consumo de agregado miúdo no sistema. Em contrapartida, as curvas para o agregado graúdo possuem inclinações negativas, indicando uma perda de abatimento ao inserir mais grãos graúdos no sistema.

O uso de cinza volante tende a aumentar o abatimento como pode ser constatado pela sua PDP, enquanto que a escória possui uma PDP de inclinação tão negativa quanto a observada para o consumo de cimento.

A adição de plastificante tem um grande impacto positivo no abatimento.

Vale ressaltar que os gráficos mostram valores negativos de abatimento, pois o modelo é testado com dados irreais, como dosagens sem água.


Figura 51 – Gráficos PDP e ICE para cada variável de entrada do modelo de previsão de abatimento



Fonte: elaborado pelo autor

A Figura 52 mostra uma curva PDP com o consumo de cimento e água. Constatase que um baixo consumo de cimento aliado a um alto consumo de água gera concretos com boa consistência. Em contrapartida, observa-se uma grande perda de abatimento ao adicionar muito cimento e pouca água na dosagem. Estes resultados estão de acordo com o apresentado na seção sobre Trabalhabilidade (seção 2.3.2), onde o aumento da quantidade de água em relação ao consumo de materiais secos provoca ganho no abatimento (GIAMMUSSO, 1992).


Figura 52 – Gráfico PDP entre abatimento e consumos de água e cimento



Fonte: elaborado pelo autor

A Figura 53 mostra a relação entre consumo de água e plastificante e o resultado do abatimento. A região de maior abatimento ocorre para consumo de água próximo à 200 kg/m^3 e consumo de plastificante próximo à 8 kg/m^3 . A seta em vermelho destaca que para quantidades fixadas de água, acrescentar plastificante irá aumentar o abatimento, evidenciando a função do plastificante em melhorar a trabalhabilidade da pasta (KOSMATKA; PANARESE; KERKHOFF, 2002). Contudo, se os consumos de água e de plastificante forem ambos muito altos, o abatimento diminui abruptamente. Uma possível explicação pra este fenômeno seria a segregação entre a pasta e os agregados causada pela alta fluidez da pasta, favorecendo o contato entre eles e, portanto, o atrito. Todavia, não se encontrou referências que embasassem esta explicação, sugerindo-se pesquisas mais aprofundadas para explicar o fenômeno neste intervalo.


Figura 53 – Gráfico PDP entre abatimento e consumos de água e plastificante



Fonte: Elaborado pelo autor

A Figura 54 mostra como a quantidade de materiais secos, isto é, cimento e agregados, afeta o abatimento. Verifica-se uma considerável perda de abatimento ao aumentar a quantidade de mistura seca, principalmente para menores consumo de água. Este resultado está de acordo com o exposto na seção sobre Trabalhabilidade (seção 2.3.2), destacando a importância do fator h em explicar o resultado de abatimento (GIAMMUSSO, 1992).


Figura 54 – Relação entre abatimento e consumo de materiais secos para diferentes consumos de água, considerando a compensação de volume nas substituições.



Fonte: elaborado pelo autor

Em relação com consumo de plastificante, o modelo explica bem a sua função de melhorar a trabalhabilidade do concreto fresco, conforme apresentado na Figura 55. Para um consumo próximo a 2,0% da massa de cimento, alcançam-se valores de abatimento acima de 180 mm.


Figura 55 – Relação entre abatimento e consumo de plastificante para diferentes consumos de cimento, considerando a compensação de volume na substituição.



Fonte: elaborado pelo autor

Outro ponto importante para ser analisado na dosagem são os efeitos provocados pela substituição do cimento por cinza volante e escória. A Figura 56 mostra que trocar cimento por cinza volante aumenta consideravelmente o abatimento, principalmente para menores quantidades de ligante, como indicado pela curva azul que atinge valores superiores a 200 mm. Este resultado está de acordo com os estudos mostrados na seção Trabalhabilidade (BERRY; MALHOTRA, 1980).

Figura 56 – Relação entre o abatimento e o consumo de cinza volante para diferentes consumos de ligante, considerando a substituição de cimento por cinza volante



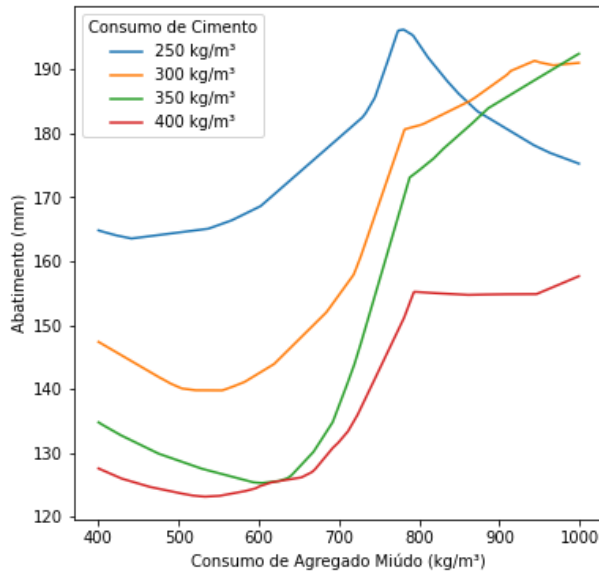
Fonte: elaborado pelo autor

Dessa forma, o modelo traz uma interpretação diferente do observado comumente na prática, em que a cinza volante precisa de mais água que o cimento para atingir a mesma consistência devido ao aumento da superfície específica do ligante. Contudo, alguns estudos na literatura encontram algo compatível com o padrão observado na Figura 56. De acordo com (SOBRAL, 2000):

Há certos casos, no entanto, em que o aumento da superfície específica do cimento, até um certo limite, mantido um mesmo volume de água, apresenta abatimentos no concreto fresco cada vez maiores, contrastando com os resultados de ensaios de cimento com consistência normal, nos quais o aumento da superfície específica exige sempre mais água. A explicação para o aparente paradoxo encontra-se no fato de que nestes últimos ensaios mede-se, principalmente, a viscosidade da pasta, enquanto que os resultados dos ensaios de abatimento são grandemente influenciados pela capacidade de lubrificação da mesma.

Um padrão semelhante é observado para a aumento de agregado miúdo na mistura, conforme apresentado na Figura 57. As curvas mostram que o aumento do consumo de finos gera concretos com melhor trabalhabilidade. Segundo o estudo sintetizado na Tabela 3, o aumento do consumo de agregado fino pela substituição de agregado graúdo, deveria piorar a trabalhabilidade (ASSUNÇÃO, 2002). Conclusão compartilhada por GIAMMUSSO (1992), vera Figura 9, o que indica uma inconsistência dos resultados deste modelo em relação ao que é comumente explicado pela literatura.

Figura 57 – Relação entre abatimento e consumo de agregado miúdo para diferentes consumos de cimento, considerando a compensação de volume na substituição



Traço padrão: 1:2:3:0,5

Consumos padrões:

Cimento: 350 kg/m³

Água: 175 kg/m³

Ag. Miúdo: 700 kg/m³

Ag. Graúdo: 1050 kg/m³

Consumo (C.) após a compensação

$\Delta C.$ de Água = 0,02 Δ Consumo de Ag. Miúdo

$\Delta C.$ de Ag. Graúdo = 0,98 $\Delta C.$ de Ag. Miúdo

Em relação ao consumo de cimento fixado:


$\Delta C.$ de Água = 0,02 $\Delta C.$ de Cimento

$\Delta C.$ de Ag. Graúdo = 0,80 $\Delta C.$ de Cimento

Fonte: elaborado pelo autor

Em relação ao agregado graúdo, os resultados do modelo produzem a mesma inconsistência, conforme apresentado na Figura 58. Concretos com mais agregado graúdo possuem menor abatimento. Isso pode ser evidenciado pela curva vermelha, na qual consumos de agregado graúdo maior que 1200 kg/m³ resultam em abatimentos inferiores a 100 mm.

Figura 58 – Relação entre abatimento e consumo de agregado graúdo para diferentes consumos de cimento, considerando a compensação de volume na substituição.



Traço padrão: 1:2:3:0,5

Consumos padrões:

Cimento: 350 kg/m³

Água: 175 kg/m³

Ag. Miúdo: 700 kg/m³

Ag. Graúdo: 1050 kg/m³

Consumo (C.) dos materiais restantes

$\Delta C.$ de Água = 0,03 Δ Consumo de Ag. Graúdo

$\Delta C.$ de Ag. Miúdo = 0,88 $\Delta C.$ de Ag. Graúdo

Em relação ao consumo de cimento fixado:

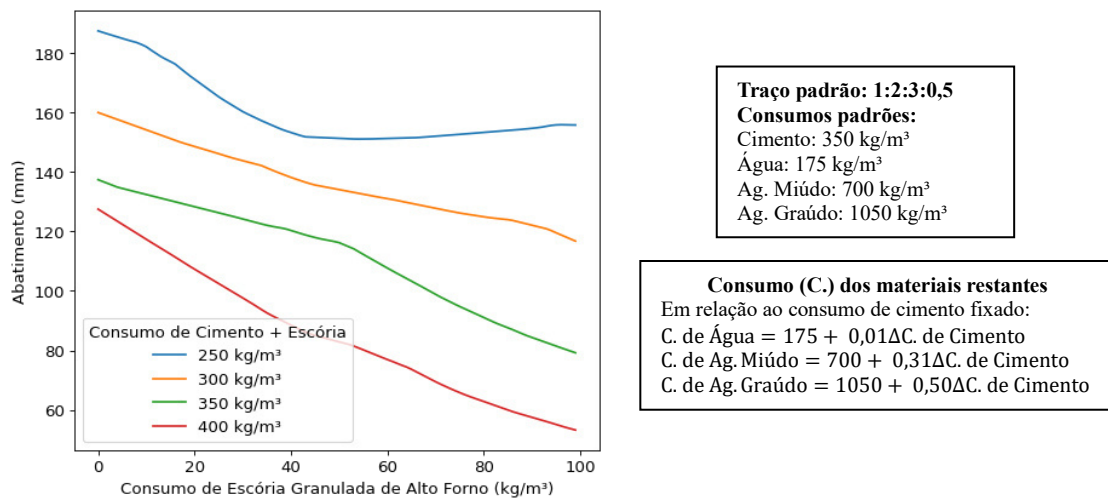
$\Delta C.$ de Água = 0,03 $\Delta C.$ de Cimento

$\Delta C.$ de Ag. Miúdo = 0,75 $\Delta C.$ de Cimento

Fonte: elaborado pelo autor

Outro material que diminui consideravelmente o abatimento é a escória. A Figura 59 apresenta o efeito causado pela substituição de cimento por escória. Observa-se que consumos elevados de escória geram concretos com menores valores de abatimento, evidenciado pela curva vermelha. Isso está de acordo com a literatura que explica que o acréscimo de escória aumenta a superfície específica da mistura.

Figura 59 – Relação entre o abatimento e o consumo de escória para diferentes consumos de ligante, considerando a substituição de cimento por escória.



Fonte: elaborado pelo autor

6 CONCLUSÕES E SUGESTÕES

Este trabalho apresentou a criação dos dois bancos de dados a partir de artigos publicados em revistas e base de dados públicas. O banco de dados com resultados de resistência à compressão foi formado a partir de 4 estudos, totalizando 1992 instâncias. O banco de dados com resultados de abatimento de tronco de cone foi constituído por 4 estudos, totalizando 784 instâncias. Os estudos utilizados muitas vezes já envolvem um agrupamento de outros estudos.

Em seguida, uma análise exploratória feita com o auxílio de *pairplots*, calculando as correlações de Pearson, mostrou ser efetiva em evidenciar comportamentos físicos entre os materiais usados na mistura e as propriedades do concreto, de maneira descritiva. O consumo de cimento, cinza volante, água e plastificante tiveram alta relação com a resistência à compressão. Enquanto isso, o abatimento é mais relacionado ao consumo de cimento, cinza volante, plastificante e agregados. Além disso, o consumo dos materiais se relaciona entre si, como agregado graúdo e miúdo, cimento e escória, cimento e cinza volante, entre outros. Essas evidências de correlações indicam a viabilidade para a adoção de modelos de aprendizado de máquina que podem captar estas dependências entre as variáveis de entrada e a propriedade em questão. Ao mesmo tempo, essas informações permitem melhor interpretar modelos mais aprofundados, estudados em seguida.

Foram, então, comparados três algoritmos de aprendizado de máquina: a Rede Neural Artificial; a Máquina de Vetor de Suporte; e a Floresta Aleatória. Os modelos foram usados tanto para classificação quanto para regressão, após otimização hiperparamétrica. Em geral, observou-se que os modelos desempenharam bem, mas a Rede Neural Artificial atingiu os melhores resultados.

No caso do modelo de classificação para previsão de resistência, a Rede Neural obteve melhores resultados, com acurácia média de 52%. Este baixo valor ocorreu pelo grande número de classes em intervalos próximos de resistência, mas ao considerar o modelo tolerante a uma classe vizinha, a acurácia média é próxima de 90%.

Em relação ao modelo de regressão para previsão de resistência, a Rede Neural também foi o modelo que obteve melhores resultados. O MAE foi 2,99 MPa, indicando uma boa performance, visto que erros dessa magnitude não são críticos em um traço inicial na dosagem. O modelo também apresentou boa capacidade de generalização, pois apresentou um R^2 de 0,796 para o conjunto de dados nunca visto pela RNA.

No que concerne ao modelo de classificação para previsão de abatimento, os três modelos tiveram resultados muito semelhantes. Optou-se pela Máquina de Vetor de Suporte, que apresentou uma precisão média de 80%. Apesar desta alta precisão, percebe-se que a maior parte das instâncias pertencem a classe S100, o que pode enviesar a previsão do modelo. Tal comportamento foi observado para as 18 instâncias que pertencem à classe S50 e foram classificadas erroneamente, assim como 7 das 15 instâncias da classe S220. Dessa forma, o modelo não está apto para prever concretos frescos com os mais baixos ou os mais altos valores de abatimento.

Em relação ao modelo de regressão para previsão de abatimento, a Rede Neural teve um menor RMSE de 37,66, enquanto o SVM obteve menor MAE de 24,47 mm. Escolheu-se a Rede Neural como o modelo principal, tendo apresentado R^2 de 0,692 com os dados de teste, indicando uma boa capacidade de generalização. Observa-se que o RMSE é consideravelmente maior que o MAE, o que indica a presença de mais *outliers* na previsão.

Em linhas gerais, os padrões identificados na previsão dos quatro modelos escolhidos em relação a diferentes dosagens definidas para um estudo de sensibilidade foram:

- a) Aumentar o consumo de cimento melhora a resistência e piora a consistência;
- b) Aumentar o consumo de água piora a resistência e melhora a consistência;
- c) Aumentar a relação *a/c* piora a resistência e melhora a consistência;
- d) Adicionar plastificante tende a melhorar a consistência, e até certo ponto pode melhorar a resistência;
- e) Substituir o cimento por cinza volante mantém a resistência até certo ponto, e melhora consideravelmente a trabalhabilidade;
- f) Substituir o cimento por escória granulada de alto forno diminui a resistência aos poucos, e piora consideravelmente a trabalhabilidade;
- g) O consumo de agregados traz conclusões diferentes para os modelos de classificação e regressão. Certos resultados não tiveram embasamento teórico, pois na literatura, considera-se outras variáveis de estudo, como a dimensão, forma e textura dos grãos, importantes para a reologia dos materiais, algo não capturado pelos modelos aqui apresentados.

Sugestões para trabalhos futuros:

- a) Aprimorar a metodologia de otimização dos hiperparâmetros dos modelos. Idealmente, realizar múltiplas buscas com o algoritmo *GridSearchCV* para

diferentes repartições dos dados em treino e teste. Essa técnica é chamada de *Nested Cross Validation* pela biblioteca *Scikit-learn* (PEDREGOSA *et al.*, 2011).

- b) Usar outras variáveis de entrada do modelo que possam explicar melhor as propriedades de resistência e reologia do concreto. Entre elas, as propriedades físicas dos agregados como módulo de finura, dimensão máxima característica, natureza dos grãos, densidade e outras. Além de especificar as classes de cinza volante, escória e plastificante.
- c) Desenvolver modelos que não considerem dosagens com cinza volante e escória, e comparar com os modelos apresentados neste trabalho. Averiguar se as conclusões das análises de sensibilidade mudam. Em particular, avaliar se o uso de materiais cimentícios afetam na quantidade de agregados necessária para alcançar uma resistência alvo.
- d) Utilizar outros traços de referência nas análises de sensibilidade para comparar o comportamento de concretos de traço mais rico e pobre.
- e) Utilizar outras regras de substituição nos cálculos da análise paramétrica. Neste trabalho foi adotado um rateio de volume baseado no traço em volume. Outras alternativas seriam controlar o teor de agregados, ou o teor de argamassa após a substituição.
- f) Adotar uma caracterização mais detalhada que distinga concretos convencionais e Concretos de Alto Desempenho, seja por meio de normas regularizadoras, ou estudos científicos. E assim, verificar se essa classificação é percebida na análise exploratória dos dados e nos estudos de sensibilidade dos modelos.

REFERÊNCIAS

- ABDELATIF, A. O. et al. Concrete mix design and aggregate tests data between 2009 and 2017 in Sudan. **Data in Brief**, v. 21, p. 146–149, 1 dez. 2018.
- ABRAHAM, A. Artificial neural networks. **Handbook of measuring system design**, 2005.
- ABRAMS, D. A. **Design of concrete mixtures**. [s.l.] Structural Materials Research Laboratory, Lewis Institute, 1919. v. 1
- ABUODEH, O. R.; ABDALLA, J. A.; HAWILEH, R. A. Assessment of compressive strength of Ultra-high Performance Concrete using deep machine learning techniques. **Applied soft computing**, v. 95, p. 106552, 2020.
- ALMEIDA, J. et al. Influence of Water Addition to Correct the Slump in Compressive Strength of Concrete Produced in Sinop - Brazil. **International Journal of Materials Engineering**, v. 8, p. 35–39, 1 jun. 2018.
- AMLASHI, A. T. et al. Soft computing based formulations for slump, compressive strength, and elastic modulus of bentonite plastic concrete. **Journal of Cleaner Production**, v. 230, p. 1197–1216, 1 set. 2019.
- AMRAN, M. et al. Slag uses in making an ecofriendly and sustainable concrete: A review. **Construction and Building Materials**, v. 272, p. 121942, 22 fev. 2021.
- ASSUNÇÃO, J. W. Curvas de dosagem para concretos convencionais e aditivados confeccionados com materiais da região Noroestes do Paraná. 2002.
- BEN CHAABENE, W.; FLAH, M.; NEHDI, M. L. Machine learning prediction of mechanical properties of concrete: Critical review. **Construction and Building Materials**, v. 260, p. 119889, 10 nov. 2020.
- BERRY, E.; MALHOTRA, V. M. **Fly ash for use in concrete-a critical review**. 1980.
- BHARATKUMAR, B. H. et al. Mix proportioning of high performance concrete. **Special Issue on Theme Analysis**, v. 23, n. 1, p. 71–80, 1 fev. 2001.
- BREIMAN, L. et al. Classification and regression trees. Belmont, CA: Wadsworth. **International Group**, v. 432, p. 151–166, 1984.
- CHANDWANI, V.; AGRAWAL, V.; NAGAR, R. Modeling slump of ready mix concrete using genetic algorithms assisted training of Artificial Neural Networks. **Expert Systems with Applications**, v. 42, n. 2, p. 885–893, 1 fev. 2015.
- CHITHRA, S. et al. A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks. **Construction and Building Materials**, v. 114, p. 528–535, 1 jul. 2016.

CHOU, J.-S. et al. Optimizing the prediction accuracy of concrete compressive strength based on a comparison of data-mining techniques. **Journal of Computing in Civil Engineering**, v. 25, n. 3, p. 242–253, 2011.

CHOU, J.-S.; TSAI, C.-F. Concrete compressive strength analysis using a combined classification and regression technique. **Automation in Construction**, v. 24, p. 52–60, 1 jul. 2012.

CONSHOHOCKEN, P. ASTM International. **Atanasova, B., Langlois, D., Nicklaus, S., Chabanet, C. et Etiévant, P**, 2004.

CORTEZ, P.; EMBRECHTS, M. J. Using sensitivity analysis and visualization techniques to open black box data mining models. **Information Sciences**, v. 225, p. 1–17, 2013.

DE CASTRO, A.; LIBORIO, J.; PANDOLFELLI, V. Reologia de concretos de alto desempenho aplicados na construção civil: revisão. **Cerâmica**, v. 57, p. 63–75, 2011.

DEEPA, C.; SATHIYAKUMARI, K.; SUDHA, V. P. Prediction of the compressive strength of high performance concrete mix using tree based modeling. **International Journal of Computer Applications**, v. 6, n. 5, p. 18–24, 2010.

DHANPAT, J.; HIGGINSON, A.; BROOKS, K. Estimation of the Effect of Bio-Admixtures on Concrete Workability Using Linear Regression and Support Vector Machines. **Control Conference Africa CCA 2021**, v. 54, n. 21, p. 133–138, 1 jan. 2021.

DJAVANSHIR, G. R.; CHEN, X.; YANG, W. A Review of Artificial Intelligence's Neural Networks (Deep Learning) Applications in Medical Diagnosis and Prediction. **IT Professional**, v. 23, n. 3, p. 58–62, 2021.

DURÁN-HERRERA, A. et al. Evaluation of sustainable high-volume fly ash concretes. **Cement and Concrete Composites**, v. 33, n. 1, p. 39–45, 1 jan. 2011.

FABRO, F. et al. Influence of fine aggregates particle shape in the concrete properties. **Revista Ibracon de estruturas e materiais**, v. 4, p. 191–212, 2011.

FRANK, E.; HALL, M. **A simple approach to ordinal classification**. Springer, 2001.

FRIEDMAN, J. H. Greedy function approximation: a gradient boosting machine. **Annals of statistics**, p. 1189–1232, 2001.

FUSHIKI, T. Estimation of prediction error by using K-fold cross-validation. **Statistics and Computing**, v. 21, n. 2, p. 137–146, 2011.

GARDNER, M. W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14, p. 2627–2636, 1 ago. 1998.

GIAMMUSSO, S. E. **Manual do concreto**. [s.l.] Pini, 1992.

GOLDSTEIN, A. et al. Peeking inside the black box: Visualizing statistical learning with plots of individual conditional expectation. **journal of Computational and Graphical Statistics**, v. 24, n. 1, p. 44–65, 2015.

HAN, Q. et al. A generalized method to predict the compressive strength of high-performance concrete by improved random forest algorithm. **Construction and Building Materials**, v. 226, p. 734–742, 30 nov. 2019.

HASTIE, T. et al. **The elements of statistical learning: data mining, inference, and prediction**. [s.l.] Springer, 2009. v. 2

HELENE, P. R.; TERZIAN, P. Manual de dosagem e controle do concreto. 1993.

INGRID, F.; TALLIS, R.; WANNER, S. APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINAS PARA SIMULAÇÃO DO COEFICIENTE DE ATENUAÇÃO LINEAR DE RAIOS GAMA EM CONCRETOS PESADOS. 2021.

KOSMATKA, S. H.; PANARESE, W. C.; KERKHOFF, B. **Design and control of concrete mixtures**. [s.l.] Portland Cement Association Skokie, IL, 2002. v. 5420

LEMAÎTRE, G.; NOGUEIRA, F.; ARIDAS, C. K. Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning. **The Journal of Machine Learning Research**, v. 18, n. 1, p. 559–563, 2017.

LYSE, I. **Tests on consistency and strength of concrete having constant water content**. 1932.

MANGALATHU, S.; JEON, J.-S. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques. **Engineering Structures**, v. 160, p. 85–94, 1 abr. 2018.

MEGAT JOHARI, M. A. et al. Influence of supplementary cementitious materials on engineering properties of high strength concrete. **Construction and Building Materials**, v. 25, n. 5, p. 2639–2648, 1 maio 2011.

MEHTA, P. K.; MONTEIRO, P. J.; CARMONA FILHO, A. **Concreto: estrutura, propriedades e materiais**. [s.l.] Pini, 1994.

MINDESS, S.; YOUNG, F.; DARWIN, D. Concrete 2nd editio. **Technical Documents**, v. 585, 2003.

MOAYEDI, H. et al. Application of three metaheuristic techniques in simulation of concrete slump. **Applied Sciences**, v. 9, n. 20, p. 4340, 2019.

MONTEIRO, P. J.; MILLER, S. A.; HORVATH, A. Towards sustainable concrete. **Nature materials**, v. 16, n. 7, p. 698–699, 2017.

NADERPOUR, H.; RAFIEAN, A. H.; FAKHARIAN, P. Compressive strength prediction of environmentally friendly concrete using artificial neural networks. **Journal of Building Engineering**, v. 16, p. 213–219, 1 mar. 2018.

NEVILLE, A. M. **Propriedades do concreto-5ª Edição**. [s.l.] Bookman Editora, 2015.

OLIVEIRA, A. L. DE. Contribuição para a dosagem e produção de peças de concreto para pavimentação. 2004.

- ONER, A.; AKYUZ, S.; YILDIZ, R. An experimental study on strength development of concrete containing fly ash and optimum usage of fly ash in concrete. **Cement and Concrete Research**, v. 35, n. 6, p. 1165–1171, 1 jun. 2005.
- ÖZTAŞ, A. et al. Predicting the compressive strength and slump of high strength concrete using neural network. **Construction and Building Materials**, v. 20, n. 9, p. 769–775, 1 nov. 2006.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **the Journal of machine Learning research**, v. 12, p. 2825–2830, 2011.
- PETRUCCI, E. G. R.; PAULON, V. A. **Concreto de cimento Portland**. [s.l.] Globo, 1993.
- QUAN, H.; KASAMI, H. Experimental Study on Durability Improvement of Fly Ash Concrete with Durability Improving Admixture. **The Scientific World Journal**, v. 2014, p. 818103, 9 jun. 2014.
- ROUSSEL, N. **Understanding the rheology of concrete**. [s.l.] Elsevier, 2011.
- RUSSELL, H. G. High-Performance Concrete--From Buildings to Bridges. **Concrete International**, v. 19, n. 8, p. 62–63, 1997.
- SIDNEY, M.; DAVID, D.; J. Concrete 2nd Edition. **Technical Documents**, 1 jan. 2003.
- SILVA, D. DE A.; GEYER, A. L. B. Influência da Forma do agregado graúdo nas propriedades mecânicas do concreto. **Revista Científica Multidisciplinar Núcleo do Conhecimento ISSN**, v. 2448, p. 0959, 2013.
- SILVA, L. A. et al. Modelagem preditiva de propriedades mecânicas em concretos reforçados com fibra de aço utilizando redes neurais artificiais. **Ambiente Construído**, v. 22, p. 215–232, 2022.
- SOBRAL, H. S. Propriedades do concreto fresco. **Ass. Bras. Cim. Portland, S. Paulo**, 2000.
- STOCK, A. F.; HANNANTT, D. J.; WILLIAMS, R. I. T. The effect of aggregate concentration upon the strength and modulus of elasticity of concrete. **Magazine of Concrete Research**, v. 31, n. 109, p. 225–234, 1979.
- TARGINO, D. et al. **Análise Exploratória de Dados de Dosagens para modelos de previsão e estimativas de resistências à compressão de Concretos Autoadensáveis**. [s.l: s.n.]. p. 495
- TIMUR CIHAN, M. Prediction of concrete compressive strength and slump by machine learning methods. **Advances in Civil Engineering**, v. 2019, 2019.
- TOPÇU, İ. B.; SARIDEMIR, M. Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic. **Computational Materials Science**, v. 42, n. 1, p. 74–82, 1 mar. 2008.
- TUTIKIAN, B. F.; HELENE, P. Dosagem dos concretos de cimento Portland. 2011.
- VAPNIK, V. The support vector method of function estimation. Em: **Nonlinear modeling**. [s.l.] Springer, 1998. p. 55–85.

YANG, L.; AN, X.; DU, S. Estimating workability of concrete with different strength grades based on deep learning. **Measurement**, v. 186, p. 110073, 1 dez. 2021.

YEH, I.-C. Modeling of strength of high-performance concrete using artificial neural networks. **Cement and Concrete Research**, v. 28, n. 12, p. 1797–1808, 1 dez. 1998.

YEH, I.-C. Exploring concrete slump model using artificial neural networks. **Journal of Computing in Civil Engineering**, v. 20, n. 3, p. 217–221, 2006.

YEH, I.-C. Simulation of concrete slump using neural networks. **Construction Materials**, v. 162, p. 11–18, 1 jan. 2009.

YEH, I.-C.; LIEN, L.-C. Knowledge discovery of concrete material using Genetic Operation Trees. **Expert Systems with Applications**, v. 36, n. 3, Part 2, p. 5807–5812, 1 abr. 2009.

ZAIN, M. F. M.; ABD, S. M. Multiple regression model for compressive strength prediction of high performance concrete. **Journal of Applied Sciences**, v. 9, n. 1, p. 155–160, 2009.

ZHANG, J. et al. Modelling uniaxial compressive strength of lightweight self-compacting concrete using random forest regression. **Construction and Building Materials**, v. 210, p. 713–719, 2019.

ZHANG, R.; XUE, X. A predictive model for the bond strength of near-surface-mounted FRP bonded to concrete. **Composite Structures**, v. 262, p. 113618, 15 abr. 2021.

ZHANG, X.; AKBER, M. Z.; ZHENG, W. Predicting the Slump of Industrially Produced Concrete from Mixture Proportions: Insights from Statistical Analysis, Data Visualization and Machine Learning. **Data Visualization and Machine Learning**, 2022.