



UNIVERSIDADE FEDERAL DE GOIÁS - REGIONAL CATALÃO
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM E OTIMIZAÇÃO



RANIERE MOISÉS DA CRUZ FONSECA

APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE
RESISTÊNCIA À COMPRESSÃO DE ARGAMASSA

DISSERTAÇÃO DE MESTRADO

CATALÃO
2021



UNIVERSIDADE FEDERAL DE GOIÁS
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese

2. Nome completo do autor

Raniere Moisés da Cruz Fonseca

3. Título do trabalho

APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE RESISTÊNCIA À COMPRESSÃO DE ARGAMASSA

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

- a) consulta ao(a) autor(a) e ao(a) orientador(a);
- b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Antover Panazzolo Sarmento, Professor do Magistério Superior**, em 30/08/2021, às 17:24, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **RANIERE MOISÉS DA CRUZ FONSECA, Discente**, em 30/08/2021, às 18:39, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2311494** e o código CRC **00367E0D**.

RANIERE MOISÉS DA CRUZ FONSECA

APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE
RESISTÊNCIA À COMPRESSÃO DE ARGAMASSA

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem e Otimização, da Unidade Acadêmica de Matemática e Tecnologia da Universidade Federal de Goiás (UFG), como requisito para obtenção do título de Mestre em Modelagem e Otimização.

Área de Concentração: Modelagem e Otimização.

Orientador:
Antover Panazzolo Sarmiento

CATALÃO
2021

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Fonseca, Raniere Moisés da Cruz
APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE RESISTÊNCIA
À COMPRESSÃO DE ARGAMASSA [manuscrito] / Raniere Moisés da
Cruz Fonseca. - 2021.
106, f.

Orientador: Prof. Dr. Antover Panazzolo Sarmento.
Dissertação (Mestrado) - Universidade Federal de Goiás, Unidade
Acadêmica Especial de Matemática e Tecnologia, Catalão,
Programa de Pós-Graduação em Modelagem e Otimização, Catalão, 2021.
Bibliografia. Apêndice.
Inclui algoritmos, lista de figuras, lista de tabelas.

1. Argamassa. 2. Predição. 3. Resistência à compressão. 4.
Aprendizado de máquinas. I. Sarmento, Antover Panazzolo, orient.
II. Título.

CDU 624



UNIVERSIDADE FEDERAL DE GOIÁS

UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 10 da sessão de Defesa de Dissertação de **Raniere Moisés da Cruz Fonseca**, que confere o título de Mestre(a) em **Mestre(a) em Modelagem e Otimização**, na área de concentração em **Modelagem e Otimização**.

Aos **30 dias de agosto de 2021**, a partir da(s) **15 h 00 min**, por Webconfência, via sistema <https://meet.google.com/rtz-pmod-epx>, reuniram-se os componentes da banca examinadora, professores(as) **Dr. Antover Panazzolo Sarmento (orientador)** (PPGMO - UFCAT), **Dr. Marcos Napoleão Rabelo** (PPGMO - UFCAT) e **Dr. Ed Carlo Rosa Paiva** (FENG - UFCAT) para, em sessão pública, procederem a avaliação da Dissertação intitulado(a) **“APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE RESISTÊNCIA À COMPRESSÃO DE ARGAMASSA”**, de autoria de **Raniere Moisés da Cruz Fonseca**, discente do Programa de Pós-graduação em Modelagem e Otimização – PPGMO, da Universidade Federal de Catalão - UFCAT. A sessão foi aberta pelo(a) presidente, que fez a apresentação formal dos membros da banca. Em seguida, a palavra foi concedida ao discente que, em 36 min procedeu a apresentação. Terminada a apresentação, cada membro da banca arguiu o examinando. Terminada a fase de arguição, procedeu-se a avaliação da Dissertação, que foi considerado(a): **(X) Aprovado ou () Reprovado(a)**. Cumpridas as formalidades de pauta, a presidência da mesa encerrou a sessão e, para constar, lavrou-se a presente ata que, depois de lida e aprovada, segue assinada pelos membros da banca examinadora e pelo discente.

Obs: *"Banca Examinadora de Qualificação/Defesa Pública de Dissertação/Tese realizada em conformidade com a Portaria da CAPES n. 36, de 19 de março de 2020, de acordo com seu segundo artigo:*

Art. 2o A suspensão de que trata esta Portaria não afasta a possibilidade de defesas de tese utilizando tecnologias de comunicação à distância, quando admissíveis pelo programa de pós-graduação stricto sensu, nos termos da regulamentação do Ministério da Educação."

TÍTULO SUGERIDO PELA BANCA

APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE RESISTÊNCIA À COMPRESSÃO DE ARGAMASSA



Documento assinado eletronicamente por **Antover Panazzolo Sarmento, Professor do Magistério Superior**, em 15/09/2021, às 10:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcos Napoleão Rabelo, Professor do Magistério Superior**, em 15/09/2021, às 10:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ed Carlo Rosa Paiva, Professor do Magistério Superior**, em 15/09/2021, às 13:47, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **RANIERE MOISÉS DA CRUZ FONSECA, Discente**, em 15/09/2021, às 15:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2347853** e o código CRC **4860FC53**.

Dedico este trabalho ao meu padrinho Lourival José Borges (in memoriam), o maior exemplo de um ser humano íntegro e apaixonado pela engenharia.

Agradecimentos

Agradeço a Deus, por ter me dado sabedoria e perseverança ao longo dessa etapa da minha vida que agora concluo.

Ao meu orientador, professor, mais do que isso, amigo Antover Panazzolo Sarmento por toda dedicação, conhecimento, paciência e pelo apoio indispensável neste trabalho.

Aos meus filhos, Benício e Théo, pelo carinho e amor incondicional, vocês tornaram essa jornada mais leve, uma leveza terna que apenas a infância possui.

A minha esposa, Isabella, pelo amor, apoio, atenção e compreensão perante as dificuldades que me afligiam durante o mestrado, que sempre esteve ao meu lado me aconselhando.

Agradeço a todos os professores Programa de Pós-Graduação em Modelagem e Otimização (PPGMO), que contribuíram para a minha formação.

Ao Programa de Pós-Graduação em Modelagem e Otimização (PPGMO) da **Universidade Federal de Goiás – Regional Catalão**, pela oportunidade de estudo.

E a todos aqueles que de algum modo colaboraram para realização deste trabalho.

*O maior inimigo do conhecimento não é a ignorância, é a ilusão do conhecimento – Stephen
Hawking*

RESUMO

FONSECA, R. M. C. *Aprendizado de Máquina para Predição de Resistência à Compressão de Argamassa*. 2021. 106 f. Dissertação (Mestrado em Modelagem e Otimização) – Unidade Acadêmica de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

O presente trabalho objetivou avaliar o desempenho de algoritmos de Aprendizado de Máquinas na predição da resistência à compressão de argamassas. O conjunto de dados avaliado passou por um pré-processamento para verificação de *outliers*, que não puderam ser removidos pois inviabilizaria a análise, em função do pequeno número amostral resultante. Optou-se por testar além dos dados brutos os dados normalizados e padronizados. Em seguida, os algoritmos: *k*-Vizinhos Próximos (*k*-NN), Máquinas de Vetor Suporte (SVM) e Floresta Aleatória (RF) foram utilizados para a predição da resistência à compressão avaliando o desempenho do modelo, onde o algoritmo RF apresentou um melhor desempenho quando comparado aos demais. Os parâmetros do algoritmo RF foram ajustados e selecionados os valores que apresentaram o menor RMSE para a divisão do conjunto de dados em treino e teste, controle da divisão dos subconjuntos, número de árvores e número de variáveis avaliadas por nó. Após determinação das melhores configurações dos parâmetros para o algoritmo selecionado o modelo foi executado novamente para verificar o desempenho do mesmo com os ajustes realizados, obtendo R^2 de 86,94%, MAE de 4,64 MPa e RMSE de 7,42 MPa, quando utilizando-se os dados de teste do modelo final obtido. Por fim, conclui-se que o Aprendizado de Máquinas (AM) é uma ferramenta de cálculo prática na predição da resistência à compressão de argamassas.

Palavras-chaves: Argamassa, Predição, Resistência à compressão, Aprendizado de máquinas.

ABSTRACT

FONSECA, R. M. C. *Machine Learning for Prediction of Resistance to Mortar Compression*. 2021. 106 f. Dissertação (Mestrado em Modelagem e Otimização) – Unidade Acadêmica de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

This study aims to evaluate the performance of Machine Learning algorithms in predicting the compressive strength of mortars. The dataset evaluated underwent a pre-processing to verify outliers, which could not be removed as it would make the analysis unfeasible, due to the small sample size that resulted. In addition to the raw data, it was decided to test the normalized and standardized data. Then, the algorithms: k – Nearest Neighbour (k-NN), Support Vector Machine (SVM) and Random Forest (RF) were used to predict the compressive strength, evaluating the performance of the model, where the RF algorithm presented a better performance when compared to the others. The parameters of the RF algorithm were adjusted and selected the values that dissipate the lowest RMSE for the division of the dataset in training and testing, control of subset division, number of tree and number of variables evaluated per node. After determining the best parameter settings for the selected algorithm, the model was obtained again to verify its performance with adjustments, obtaining R^2 of 86.94%, MAE of 4.64 MPa and RMSE of 7.42MPa, when using test data from the final model. Finally, it is concluded that Machine Learning (ML) is a practical calculation tool in predicting the compressive strength of mortars.

Keywords: Mortar, Prediction, Compressive strength, Machine learning.

LISTA DE FIGURAS

Figura 2.1 – Tipos de areia com matriz de rocha distinto utilizados na produção de argamassas.....	30
Figura 2.2 – Areais obtidas após o processo de britagem.....	31
Figura 2.3 – Resíduo de corte de pedras decorativas.....	33
Figura 3.1 – Limite de decisão 1-NN.....	42
Figura 3.2 – Ilustração função de aproximação RVS.....	45
Figura 3.3 – Técnica de <i>bootstrap</i> aplicada na criação de B conjunto de dados.....	48
Figura 3.4 – Esquema de funcionamento de uma RF.....	49
Figura 4.1 – Fluxograma das técnicas utilizadas para predição de resistência de argamassas.....	50
Figura 4.2 – Pagina inicial Software R.....	52
Figura 5.1 – Gráfico de <i>boxplot</i> dados brutos.....	63
Figura 5.2 – Gráfico de correlação das variáveis.....	64
Figura 5.3 – Importância das variáveis no desempenho do modelo.....	76
Figura 5.4 – Resistência à compressão real <i>versus</i> predita.....	77

LISTA DE TABELAS

Tabela 4.1 - Consumo de insumos traços para a produção de 1 m ³ de argamassa.....	51
Tabela 5.1 – Estatística descritiva dos dados brutos.....	62
Tabela 5.2 – Estatística descritiva dos dados brutos sem <i>outliers</i>	64
Tabela 5.3 – Estatística descritiva dos dados padronizados.....	66
Tabela 5.4 – Estatística descritiva dos dados normalizados.....	66
Tabela 5.5 – Coeficiente de determinação dados brutos.....	67
Tabela 5.6 – Coeficiente de determinação dados padronizados.....	67
Tabela 5.7 – Coeficiente de determinação dados normalizados.....	67
Tabela 5.8 – RF para dados brutos controle = 5.....	69
Tabela 5.9 – RF para dados brutos controle = 10.....	70
Tabela 5.10 – RF para dados brutos controle = 5 e repetições = 5.....	71
Tabela 5.11 – RF para dados brutos controle = 10 e repetições = 5.....	72
Tabela 5.12 – Quantidade de árvores para dados brutos.....	74
Tabela 5.13 – Avaliação no número de variáveis avaliadas por nó.....	75
Tabela 5.14 – Resumo final modelo RF parâmetros ajustados.....	78
Tabela A – Banco de dados argamassa.....	92

LISTA DE QUADROS

Quadro 2.1 – Características cimento Portland conforme NBR 16697 (ABNT, 2018)	28
Quadro 2.2 – Influência da granulometria da areia nas propriedades das argamassas.....	32
Quadro 2.3 – Consumo de cimento em kg por m ³ de argamassa	37
Quadro 3.1 – Funções de Kernel mais utilizadas	47
Quadro 4.1 – Parâmetros de ajuste dos algoritmos	55

LISTA DE ALGORITMOS

Algoritmo 4.1 – Algoritmo para verificação dos pontos fora da curva.....	53
Algoritmo 4.2 – Algoritmo para padronização e normalização dos dados.....	54
Algoritmo 4.3 – Algoritmo aprendizado de máquinas.....	56
Algoritmo 4.4 – Algoritmo determinação melhor split e controle.....	57
Algoritmo 4.5 – Algoritmo determinação melhor número de árvores.....	57
Algoritmo 4.6 – Algoritmo determinação melhor <i>mtry</i>	58

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Objetivo Geral	22
1.2	Objetivos Específicos	22
2	ARGAMASSA	23
2.1	Características da Argamassa	23
2.2.1	Cimento Portland.....	26
2.2.2	Cal	29
2.2.3	Areia	30
2.2.4	Aditivos	34
2.2	Dosagem de Argamassa	35
2.3	Aprendizado de máquinas na predição da resistência de misturas cimentícias 37	
3	APRENDIZADO DE MÁQUINAS	39
3.1	Aprendizado de máquinas	39
3.2	Tipos de aprendizado de máquinas	40
3.2.1	<i>k</i> -Vizinhos Próximos (<i>k</i> -Nearest Neighbour – <i>k</i> -NN).....	41
3.2.2	Máquina de Vetor Suporte (<i>Support Vector Machine</i> - SVM).....	43
3.2.3	Floresta Aleatória (<i>Random Forest</i> - RF).....	47
4	MATERIAIS E MÉTODOS	50
4.1	Coleta de dados	50
4.2	Linguagem de Programação	51
4.3	Verificação de dados fora da curva	52
4.4	Verificação da correlação das variáveis	53
4.5	Pré-processamento do conjunto de dados	54
4.6	Avaliação de desempenho dos modelos de AM	55
4.7	Calibração dos parâmetros de ajuste	56
4.8	Ferramentas de avaliação do desempenho do modelo	58
4.8.1	Coefficiente de determinação	58
4.7.2	Raiz quadrada do erro médio.....	59
4.7.3	Erro absoluto médio	59

5	RESULTADOS E DISCUSSÕES	61
5.1	Caracterização dos dados	61
5.2	Verificação dos pontos fora da curva	61
5.3	Verificação de correlação das variáveis	64
5.4	Pré-Processamento do conjunto de dados	65
5.5	Avaliação de desempenho dos modelos de AM	66
5.6	Calibração dos parâmetros de ajuste	68
5.6.1	Determinação da separação entre treino e teste e método de controle.....	68
5.6.2	Determinação da quantidade de árvores	73
5.6.3	Determinação no número de variáveis avaliadas nos nós.....	75
5.7	Avaliação do algoritmo <i>Random Forest</i> após calibração dos parâmetros	77
6	CONSIDERAÇÕES FINAIS	79
6.1	Sugestões de trabalhos futuros	80
	REFERÊNCIAS	81
	APÊNDICE A BANCO DE DADOS – RESISTÊNCIA À COMPRESSÃO ARGAMASSAS	92

Capítulo 1

INTRODUÇÃO

A construção civil é de extrema importância para a economia do país, por ser grande geradora de empregos e movimentar toda uma cadeia de suprimentos. Estima-se que entre 20 e 50% das extrações de recursos naturais no mundo estão ligadas à indústria da construção (SJÖSTRÖM, 1996 *apud* SANTOS *et al.*, 2011).

Atrelado ao elevado consumo de matéria prima tem-se observado o exaurimento de jazidas de extração de agregado natural e com isso um crescimento no uso de agregado artificial de variadas matrizes de rocha (CARASEK *et al.*, 2016).

Para que a construção civil seja sustentável e tecnicamente viável a diminuição na geração e a reutilização de resíduos na própria indústria é de extrema importância. Estima-se que em 2018 no Brasil foram coletadas mais de 122 mil toneladas de Resíduo de Construção e Demolição (RCD) por dia (ABRELPE, 2019).

Embora existam diversas pesquisas que tratam da adição de agregados reciclados nas misturas de argamassa o custo e tempo de realização e validação dos traços tornam sua aplicação inviável à indústria da construção.

Para que o emprego de materiais de reuso nas misturas torne-se viável há a necessidade da utilização de um método robusto para a predição da resistência à compressão (MARANGU, 2020), bem como de suas demais características, e que apresente resultados confiáveis e com rapidez.

Desse modo, a inteligência artificial tem servido como técnica que permite o estudo da predição da resistência à compressão das argamassas, como foi observado nos trabalhos de Czarnecki *et al.* (2021), Onyarie e Ikotun (2018), Salih *et al.* (2021) e Asteris *et al.* (2021), com baixo custo e rapidez, apresentando resultados satisfatórios que viabilizam diminuir custos de pesquisas experimentais e o direcionamento de traços/dosagens para a utilização de resíduos de construção e demolição em sua constituição.

1.1 Objetivo Geral

Propor um modelo de predição de resistência à compressão para argamassas tradicionais e, ou, com a utilização de agregados artificiais e de resíduos da construção civil, utilizando técnicas de aprendizado de máquina.

1.2 Objetivos Específicos

- Realizar uma revisão bibliográfica sobre argamassa;
- Fazer uma revisão sobre aprendizado de máquinas e os métodos k – vizinhos próximos, máquinas de vetor suporte e floresta aleatória;
- Juntar dados da literatura e gerar um banco de dados com informações de traços (considerando o consumo em kg m^{-3}) de cimento, cal, areia natural, areia reciclada/artificial, resíduo de marmoraria, aditivo plastificante, água, dias de cura e resistência à compressão;
- Tratar o conjunto de dados e avaliar o efeito de dados brutos e tratados (normalizados e padronizados) na predição;
- Avaliar o banco de dados utilizando métodos de Aprendizado de Máquinas;
- Determinar a melhor separação treino/teste do conjunto de dados;
- Testar diferentes parâmetros para o método escolhido;
- Propor um modelo de predição de resistência à compressão de argamassas.

Capítulo 2

ARGAMASSA

O objetivo deste capítulo é a introdução de conceitos fundamentais para a realização de uma análise acerca das argamassas, suas características normativas, materiais constituintes e aplicação de aprendizado de máquinas na predição da resistência.

2.1 Características da Argamassa

O homem ao longo dos séculos vem se preocupando com o estudo da produção de materiais e misturas com a finalidade de unir diferentes materiais e permitir a estabilidade da estrutura por ele criada. Bauer (2008) cita que foram encontrados vestígios da utilização de concreto à aproximadamente 4.000 a.C., em edificações onde hoje é situado o Iraque.

Foram encontrados vestígios da utilização de uma mistura de aglomerantes pelos Egípcios na construção de túmulos e das pirâmides no Egito antigo, existindo vestígios de que era empregado cal como aglomerante (RECENA, 2012). Os romanos anos após desenvolveram e intensificaram o uso da cal como aglomerante, associando-a com cinzas do monte Vesúvio (BAUER, 2008). Tal técnica foi largamente utilizada pelos Gregos no mesmo período histórico, sendo a utilização da pozolana uma técnica desenvolvida para tratamento de superfícies quanto à umidade, sendo considerada assim a primeira argamassa hidráulica da história (RECENA, 2012).

Carasek (2010) lembra que as argamassas modernas possuem ainda em sua composição cimento Portland e algum aditivo orgânico para melhorar alguma propriedade da mistura, tais aditivos podem ser do tipo incorporadores de ar ou retentores de água. Pode-se mencionar ainda aditivos inibidores de retração (FIORITO, 2009).

O aglomerante cimento Portland que é base para as misturas com finalidade da produção de argamassa ou concretos só foi descoberto e patentado conforme o conhecemos na atualidade no século XIX, na Inglaterra (BAUER, 2008).

A NBR 13281 (ABNT, 2005) define argamassa como a mistura homogênea de agregados, aglomerantes inorgânicos e água, podendo conter ainda aditivos, possuindo como características aderência e endurecimento após realização da mistura, mistura essa que pode ser realizada no canteiro de obras ou em indústrias.

A NBR 13529 (ABNT, 2013) diferencia as argamassas em relação à:

- Natureza, tipo e número de aglomerantes;
- Propriedades;
- Função da argamassa;
- Condições de fornecimento ou preparo.

A definição de argamassa mostra o quão complexo é o processo de produção de argamassa, falhas no processo de produção podem ainda acarretar no aparecimento de patologias devido a existência de erros no processo de mistura.

Carasek (2010), Recena (2012) e Sabbatini (1998) apresentam as propriedades da argamassa:

- **Trabalhabilidade** - Deve ser entendida como uma propriedade complexa resultante da associação de outras propriedades, tais como: consistência e plasticidade, medidos conforme estabelecido na NBR 7215 (ABNT, 1997), retenção de água, coesão, exsudação, densidade de massa (NBR 13278 – ABNT, 2005) e adesão inicial (não existe método normatizado no Brasil).
- **Retenção de água** - Pode ser entendida como a capacidade de uma argamassa tem de reter a água de amassamento e liberá-la lentamente para o ambiente e absorção do local de aplicação, influenciando assim na trabalhabilidade. Devendo ser observado que quanto maior a quantidade de água utilizada para a produção de argamassa, maior será a evaporação e conseqüentemente maior será a retração dela. Podendo ser analisada a retenção conforme procedimento da NBR 13277 (ABNT, 2005).
- **Aderência** - É entendida como uma das propriedades mais importantes das argamassas, pois é a capacidade que a argamassa em estado fresco tem de se ficar unida ao local de aplicação. A aderência não é um fator que demanda apenas das propriedades da argamassa, como também do substrato que se aplica

e da mão-de-obra que executa o processo de aplicação, sendo uma propriedade mecânica oriunda da relação entre o substrato e argamassa, não sendo possível tratar da mesma sem considerar o substrato. A normatização brasileira trata da aderência nas NBRs 15258 (ABNT, 2005) e 13528 (ABNT, 2010).

- **Retração** - Pode ser caracterizado como a diminuição do volume das argamassas decorrente da perda de água com o passar do tempo, podendo ainda ocorrer muito tempo após o término da cura do aglomerante. É possível observar tal evento quando se tornam visíveis a ocorrência de trincas na argamassa de revestimento, sendo necessário, no entanto diferenciar trincas no revestimento de trincas do substrato que aparecem no revestimento. O revestimento de argamassa pode ser entendido como uma placa, visto que duas dimensões são maiores que a terceira, facilitando assim a perda de água para a superfície e o substrato. O ensaio de retração é estabelecido pela NBR 8490 (ABNT,1984).
- **Absorção de deformações** - As argamassas devem apresentar a capacidade de absorver pequenas deformações sem que apresentem na superfície fissuras de forma a não comprometer a aderência ao substrato, estanqueidade e durabilidade.
- **Resistência à compressão** - Sua determinação deve levar em consideração a finalidade da argamassa produzida, pois pode ser entendido que para os casos de assentamento e revestimento tal característica é deixada de lado, visto que é comum a utilização de traços pré-determinados, sem a real observância da resistência da mesma, por mais que seja uma propriedade muito importante das argamassas é deixada de lado no processo executivo. A observação da resistência à compressão é determinada pela NBRs 13279 (ABNT, 2005) e 13281 (ABNT, 2005).
- **Durabilidade** - É entendido como a capacidade de manter estável mesmo sofrendo ações externas, tais como intempéries, químicas e decorrentes de processos físico-químicos que incidem na argamassa em estado fresco e endurecido.

A NBR 13281 (ABNT, 2005) classifica as argamassas quanto ao tipo de utilização da mesma, sendo essa classificação a seguinte:

- **Argamassa para assentamento** - Indicada para o assentamento de elementos de vedação, podendo ser do tipo cerâmica ou blocos cimentícios, com função estrutural, de vedação ou encunhamento;
- **Argamassa para revestimento de paredes e tetos** - Indicada para revestimentos interno ou externos da edificação, caracterizando-se como camada de regularização (emboço ou massa única);
- **Argamassa de uso geral** - Indicada para a execução de assentamento de alvenaria sem função estrutural e revestimento de paredes e tetos internos e externos;
- **Argamassa de reboco** - Indicada para o cobrimento do emboço, resultando numa superfície fina que permite o recebimento do acabamento;
- **Argamassa decorativa em camada fina** - Argamassa de acabamento indicada em revestimentos com fins decorativos, em camada fina;
- **Argamassa decorativa em monocamada** - Argamassa de acabamento indicada para revestimento de fachadas, muros e outros elementos de edificação em contato com o meio externo, aplicada única camada e com fins decorativos.

2.2.1 Cimento Portland

A NBR 11172 (ABNT, 1990) define o cimento Portland como um aglomerante hidráulico artificial, obtido pela moagem do clínquer Portland, sendo geralmente feita a adição de uma ou mais formas de sulfato de cálcio. O cimento pode ser considerado como o aglomerante mais utilizado no mundo.

Ambrozewicz (2012) afirma que o cimento é sem dúvida o mais importante aglomerante, sendo de suma importância o conhecimento de suas propriedades físicas e mecânicas.

O cimento Portland por ser industrializado apresenta um bom controle de produção, não sendo o agente causador de patologias em argamassas e concretos, podendo ser considerado os principais agente causadores de tais patologias a mão-de-obra, agregados de qualidade insatisfatórias, agentes externos agressivos e dosagem em excesso ou insuficiente do mesmo para a mistura (CARASEK, 2010).

Sabbatini (1998) lembra que há uma grande quantidade de empresas produtoras de cimento no Brasil, contudo, não há grandes divergências na qualidade de argamassa em virtude da pequena quantidade do aglomerante na mistura.

A normatização brasileira classifica o cimento Portland com relação a sua composição e misturas feitas ao *clínquer*, possuindo assim para cada composição uma denominação, sendo as especificações unificadas na NBR 16697 (ABNT, 2018), pois até então cada tipo de cimento possuía uma norma de requisitos, facilitando assim a especificação do cimento necessário para cada tipo de serviço, não sendo então necessária consulta das oito publicações normativa existentes. A única classe de cimento não contemplada na NBR em vigor é o cimento Portland para poços petrolíferos, que atende aos requisitos da NBR 9831 (ABNT, 2020).

Os tipos de cimento normatizados e comercializados no Brasil podem ser vistos no Quadro 2.1, bem como as características inerentes a cada tipo, especificados pela norma. Nele estão apresentados os tipos de cimento Portland que são resistentes à sulfatos (RS) e os de baixo calor de hidratação (BC), podendo quaisquer dos tipos de cimento especificados no quadro ser destas classes, desde que apresentem o sufixo em sua documentação e atendam os parâmetros das normas pertinentes.

Quadro 2.1 – Características cimento Portland conforme NBR 16697 (ABNT, 2018).

NOME TÉCNICO	SIGLA	RESISTÊNCIA COM 1 DIA	CLASSE DE RESISTÊNCIA (MPa) AOS 28 DIAS	SUFIXO	COMPONENTES (% DE MASSA)			TEMPO INÍCIO DE PEGA (min)	ÍNDICE DE BRANCURA
					CLINQUER + SULFATOS DE CÁLCIO	ADIÇÕES			
						ESCÓRIA DE ALTO-FORNO	MATERIAL POZOLÂNICO (POZOLANA)		
CIMENTO PORTLAND COMUM	CP I	-			95 - 100	0 - 5	0 - 5	0 - 5	
CIMENTO PORTLAND COMUM COM ADIÇÃO	CP I - S	-			90 - 94	-	-	-	
CIMENTO PORTLAND COMPOSTO COM ESCÓRIA	CP II - E	-			51 - 94	6 - 34	-	0 - 15	
CIMENTO PORTLAND COMPOSTO COM POZOLANA	CP II - Z	-	25, 32 E 40		71 - 94	-	6 - 14	0 - 15	
CIMENTO PORTLAND COMPOSTO COM FILER	CP II - F	-		RS E BC	75 - 89	-	-	11 - 25	
CIMENTO PORTLAND DE ALTO-FORNO	CP III	-			25 - 65	35 - 75	-	0 - 10	
CIMENTO PORTLAND POZOLÂNICO	CP IV	-			45 - 85	-	15 - 50	0 - 10	
CIMENTO PORTLAND DE ALTA RESISTÊNCIA INICIAL	CP V	≥ 14	ARI		90-100			0 - 10	
CIMENTO PORTLAND BRANCO ESTRUTURAL	CP B	-	25, 32 E 40		75 - 100	-	-	0 - 25	≥ 78
CIMENTO PORTLAND BRANCO NÃO ESTRUTURAL		-	-	-	50 - 74	-	-	26 - 50	≥ 82

Fonte: Adaptado pelo autor de NBR 16697 (ABNT, 2018).

2.2.2 Cal

A NBR 11172 (ABNT, 1990) define a cal como aglomerante cujo principal constituinte é o óxido de cálcio ou óxido de cálcio em presença natural com óxido de magnésio, hidratado ou não.

Segundo Bauer (2008) a cal pode ser encontrada de dois tipos:

- **Cal virgem:** que ainda não é o aglomerante a ser utilizada, sendo necessário a extinção da mesma para que o óxido de cálcio se torne hidróxido de cálcio, e possa assim se tornar um aglomerante hidráulico;
- **Cal hidratada:** é empregada em argamassas mistas com o intuito de melhorar a trabalhabilidade da argamassa. É oriunda da extinção da cal virgem por meio da adição de água e posterior peneiramento para que seja possível a retirada da parte não extinta e, ou, impurezas.

A cal pode ser aplicada como único aglomerante em argamassas de cal e areia aplicadas como reboco sobre camada de emboço e utilizada em argamassa mista composta de cimento, cal e areia.

Cada um dos tipos de cal virgem e hidratada é padronizado por uma norma regulamentadora, NBR 6453 (ABNT, 2003) e NBR 7175 (ABNT, 2003) respectivamente.

Recena (2012) apresenta o quanto é complexo o processo de fabricação da argamassa quando se era empregada a cal virgem e que a mesma demandava tempo para hidratação e que as vezes era estocada de qualquer maneira, originando assim falhas e acarretando patologias.


Ambrozewicz (2012) lembra ainda que na evolução dos materiais de construção no que trata da resistência da argamassa à compressão a cal contribuía muito pouco, sendo deixada em desuso após o desenvolvimento do cimento, posteriormente foi observado que havia outras propriedades inerentes à argamassa que só eram obtidas com o uso da cal, podendo ser citadas, plasticidade, retenção de água e resistência a deformações.

2.2.3 Areia

As areias utilizadas na produção de argamassas e concretos podem ser originárias de uma matriz de rocha bastante vasta, ocasionando assim propriedades distintas à mistura (SABBATINI, 1998).

Carasek *et al.* (2016) analisou em seu trabalho a influência da areia nas propriedades das argamassas em estado fresco, a Figura 2.1 apresenta as areias utilizadas no experimento, uma areia natural e as demais areias artificiais (britadas) com matriz de rocha distintas, concluindo em seu estudo que as características do agregado influenciam fortemente nas propriedades da argamassa.

Figura 2.1 – Tipos de areia com matriz de rocha distinto utilizados na produção de argamassas.



Fonte: Carasek *et al.* (2016).

Recena (2012) lembra que as areias comumente utilizadas para a produção de argamassa popularmente denominadas de areia fina e média apresentam variações granulométricas de região para região. Sabbatini (1998) lembra que as características mais importantes nas areias utilizadas na construção civil são granulometria e composição mineralógica, pois interferem diretamente nas propriedades das argamassas.

É comum no canteiro de obras dependendo da granulometria entregue pelo fornecedor que os oficiais realizem a mistura de diferentes granulometrias de areia para melhorar assim alguma característica necessária para a atividade.

Recena (2012) apresenta em seu trabalho o método de dosagem do CIENTEC e apresenta como critério inerente à dosagem o processo de mistura de areias fina e média em proporções satisfatórias para assim obter uma diferença mínima entre massa específica e massa unitária, possibilitando um melhor acabamento superficial.

2.2.3.1 Areia artificial de RCD


Dentro do grupo de areias classificadas como artificiais é possível incluir as areias originárias de resíduos da construção civil (RCC), por se tratar de um agregado originado por meio do processo de britagem de resíduos descartados provenientes de obras.

A Resolução N° 307 (CONAMA, 2002) e suas alterações (CONAMA, 2004; 2011; 2012; 2015) estabelecem as diretrizes, critérios e procedimentos para a gestão dos resíduos da construção civil, dividindo-os em classes, onde os resíduos de Classe A são reutilizáveis ou recicláveis como agregado.

Segundo Carasek *et al.* (2018) é comum por parte dos pesquisadores classificar os agregados artificiais produzidos com resíduo de construção ou demolição (RCD) conforme sua matriz formadora (cimentício, argiloso ou misto), considerando também sua origem (construção, demolição e restos de fábricas), procedendo assim uma análise visual do material constituinte.

Na Figura 2.2A e 2.2B são apresentadas as pilhas de agregado miúdo reciclado na usina instalada no complexo do aterro municipal de Catalão - GO, sendo areia média e areia fina respectivamente, ao se analisar as pilhas de agregado artificial é possível observar que se trata de uma areia com matriz formadora do tipo mista.

Figura 2.2 – Areais obtidas após o processo de britagem.



Fonte: o autor.

Pimentel *et al.* (2018) em seu estudo observou que a areia de RCD por ter uma quantidade maior de finos tem uma melhora na trabalhabilidade da argamassa, pode inferir também que há uma melhora na retenção de água, fator esse primordial para a hidratação do cimento.

Segundo Santos *et al.* (2020), em seu trabalho foi identificado que o aumento do percentual de agregado reciclado nos traços de argamassa para contrapiso e emboço acarretou na variação considerável dos valores de resistência à tração na flexão e à compressão, contudo, a argamassa se manteve na mesma classe do ensaio da NBR 13281 (ABNT, 2005).

Nars *et al.* (2020), utilizando agregado proveniente da britagem de blocos de concreto celular auto clavado na produção de argamassas, conseguiram verificar que a substituição da areia natural por areia artificial oriunda de RCD em teores de até 5% em massa permite o ganho de resistência de 6,4% aos 28 dias com relação ao traço de controle.

‘ *et al.* (2020) utilizando agregado reciclado do tipo misto controlando os percentuais de cada matriz formadora (cinza e vermelha) em quantidades iguais na substituição de 15% do agregado natural por artificial possibilitou verificar que a resistência aos 28 dias da argamassa fosse de 31 MPa tanto para com o traço de controle quanto para o traço com substituição.

No Quadro 2.2 está apresentado a influência exercida sobre as propriedades da argamassa com relação as características do agregado, mostrando que a granulometria do agregado pode tanto beneficiar quanto prejudicar as propriedades das argamassas.

Carasek *et al.* (2016) em seu trabalho concluiu que areias com melhor distribuição granulométrica e grãos menos angulosos apresentam um maior empacotamento de partículas, com isso uma menor porosidade.

Quadro 2.2 – Influência da granulometria da areia nas propriedades das argamassas.

Propriedades	Menor módulo de finura	Granulometria descontínua	Maior quantidade de grãos angulosos
Trabalhabilidade	Melhor	Pior	Pior
Retenção de água	Melhor	Variável	Melhor
Retração na secagem	Aumenta	Aumenta	Variável
Porosidade	Variável	Aumenta	Variável
Resistência mecânica	Variável	Pior	Variável

Fonte: Adaptado de Sabbatini (1998).

2.2.3.2 Resíduo de marmoraria

A exploração de rochas ornamentais para sua utilização na construção civil também é uma grande geradora de resíduos, podendo considerar tais resíduos como RCD, pois sua extração e aplicação final dá-se quase que em sua totalidade na construção civil.

Os resíduos gerados pelo processo de corte e acabamento fino de peças em rochas ornamentais no município de Catalão são encaminhados para o aterro sanitário do município, ficando depositado junto dos RCDs, nas Figuras 2.3A e 2.3B é possível observar tanto os recortes como o pó do corte das rochas aguardando retirada para ser encaminhado para o aterro sanitário do município.

Figura 2.3 – Resíduo de corte de pedras decorativas.



Fonte: o autor.

O emprego de resíduos de granito em argamassa proporciona sustentabilidade à indústria de mineração de rochas ornamentais, podendo ainda serem utilizados como agregado em substituição à areia e como aglomerante em substituição ao cimento (AGRAWAL *et al.* 2021).

Bacarji *et al.* (2013) utilizaram subprodutos gerados da produção de agregado graúdo de rocha granítica, sendo tais subprodutos areia artificial e pó de pedra na produção de microconcreto, obtendo resultados satisfatórios tanto em estado fresco quanto endurecido, concluído que uma adição de 5% em teor de massa de cimento de pó de pedra possibilitou um ganho de resistência à compressão do concreto, permitiu também avaliar que no estado fresco o concreto apresentou maior fluidez, uma menor massa específica e menor segregação.

Petry *et al.* (2017) concluíram que a adição de teores de 10 e 20% de pó de rocha ornamental na produção de concreto não acarreta variação de resistência no mesmo, contudo, proporciona aumento da absorção de água, especificamente para a dosagem com 10% de adição.

Llajaruna (2016) em sua pesquisa realizou a adição de pó de marmoraria e agregado reciclado na produção de blocos de solo-cimento, observando que no estado fresco as adições

melhoraram a trabalhabilidade da mistura, já no estado endurecido a adição de um elevado percentual de adição prejudica a resistência da mistura.

No estudo realizado por Agrawal *et al.* (2021) para traços de 1:4 e 1:6 onde foi realizada a substituição da areia de rio por resíduos da produção de granito, aos 7 dias houve um ganho na resistência de 29,41% para o primeiro traço e de 49,33% no segundo para a substituição de 50% do agregado, para percentuais superiores houve um decréscimo significativo na resistência, obtendo valores inferiores ao traço de controle.

Moura *et al.* (2002) utilizaram o Resíduo do Beneficiamento do Mármore e Granito (RBMG) como agregado para a produção de argamassas de revestimento e lajotas em teores de 5 e 10%, o estudo possibilitou concluir que a substituição de 10% possibilita um ganho de resistência em todas as idades.

Alguns autores, no entanto, observaram que a substituição de aglomerante por resíduo de granito implica na diminuição da resistência à compressão de argamassas. Amin *et al.* (2020) realizaram a substituição de 5% do teor de cimento por resíduo de mármore e observaram uma redução da resistência à compressão aos 28 dias de 16,19%.

Agrawal *et al.* (2021) utilizaram pó de granito como substituição de 25 e 50% do cimento para os traços de 1:4 e 1:6, obtendo uma redução na resistência à compressão das misturas no traço de 1:4 apresentou a diminuição da resistência 49,90% substituindo 25% do aglomerante e a diminuição de 70% na resistência com 50% de substituição quando comparados ao traço de controle, para o traço de 1:6 mediram o decréscimo na resistência de 50,48% e 70% para os teores de substituição de 25% e 50% respectivamente.

2.2.4 Aditivos

Na construção civil tem-se observado o largo uso de aditivos e, ou, adições para a produção de argamassas. Carasek (2010) lembra que tais aditivos são empregados com o intuito de melhorar alguma propriedade da argamassa produzida.

Para Recena (2010) o crescimento no uso de aditivos decorre de problemas apresentados em argamassas de cal e areia, motivado muitas vezes pela baixa qualidade da jazida onde era extraído o aglomerante, contudo, os problemas com a qualidade das argamassas se mantiveram,

já que os problemas são decorrentes da dosagem sem critérios técnicos, sendo em muitos casos apenas práticos.

Nos canteiros de obra tem-se observado que o principal exemplo são os aditivos incorporadores de ar, que auxiliam na melhora da trabalhabilidade da argamassa. Carasek (2010) salienta que é necessário cautela no seu uso, pois um uso de quantidade indiscriminada poderá acarretar problemas de aderência e resistência nas argamassas.

É possível observar também o uso de aditivos hidrófugos em argamassas com o intuito de proceder a impermeabilização de superfícies, a NBR 9575 (ABNT, 2003) apresenta os critérios de projeto e seleção de impermeabilização, apresenta ainda que as argamassas com hidrofugante não podem ser industrializadas, devendo ser produzidas no canteiro de obras.

A utilização desse tipo de aditivo visa a prevenção de patologias decorrentes da infiltração de água por capilaridade ou umidade no acabamento do revestimento.

2.2 Dosagem de Argamassa

Quando se trata especificamente da dosagem de argamassas não se tem uma posição formada quanto ao modelo com melhor desempenho final, publicações técnicas largamente utilizadas na cadeira de materiais de construção civil não abordam o processo de dosagem de argamassas, dando foco principal ao concreto.

O processo de dosagem das argamassas é bastante empírico, ficando quase que em sua totalidade sobe responsabilidade do encarregado de obras com base na sua experiência (GOMES; NEVES, 2002).

Fiorito (2009) e Carasek (2010) fazem referência a NBR 7200 (ABNT, 1982), que apresenta volumes para argamassa de revestimento, e que a versão atual da referida norma (NBR 7200, ABNT 1998) não traz tal informação em seu conteúdo, não havendo assim especificação normativa para a dosagem de argamassas.

Para uma execução mais precisa em campo o recomendado seria que fosse realizado todo o processo de dosagem em massa, contudo, essa condição é impraticável nos canteiros de obra brasileiros (AMBROZEWICZ, 2012).

O processo empírico de dosagem o não controle tecnológico de argamassas e ausência de um procedimento de manutenção de argamassas de revestimento causa o aparecimento e proliferação de patologias (GOMES; NEVES, 2002).

Recena (2012) traz que algumas instituições defendem o uso de traços fixos, sem, no entanto, levar em consideração a diversidade da matriz de rocha que origina tanto a cal quanto o clínquer de cimento, adições possíveis de serem realizadas para a conformação do cimento Portland e as características do agregado que será empregado.

O processo de dosagem em bancada de laboratório é de suma importância, contudo, não deve ser entendido como o resultado definitivo para a obtenção do traço ótimo, tal resultado deve ser uma interação entre bancada e obra (RECENA, 2012).

Como quando analisamos o critério de trabalhabilidade apresentado anteriormente, que é uma característica relativa, que variará de oficial para oficial, sendo necessário então a análise dos parâmetros que se fizerem necessários com relação à consistência requerida pelo operário.

Gomes e Neves (2002) lembram ainda que a adoção de traço em volume fixo tal como 1:3 não é muito praticado em campo, pois o traço é modificado pelo encarregado de campo por achar que o traço está “fraco” ou com “pouca liga”, acarretando assim um consumo mais elevado de aglomerante, onerando o custo da edificação.

Recena (2012) diz que a adoção de aditivos permite que seja possível a produção de uma argamassa mais fraca, pois há um acréscimo no volume de pasta produzido, permitindo assim a adoção de traços de 1:8 e até 1:12, não levando em conta as características dos insumos nem propriedades desejadas para as argamassas.

A TCPO (PINI, 2017) em suas composições, apresenta a composição da argamassa de cimento, areia e aditivo aglutinante, traço 1:8, e especifica um consumo de 182 kg de cimento por metro cúbico de argamassa produzida, tanto para areia fina quanto areia média, desde que peneiradas.

Gomes e Neves (2002) em seu estudo apresentam valores estimados de consumo de cimento de acordo com o tipo de uso e região de aplicação da argamassa conforme apresentado na Quadro 2.3.

Quadro 2.3 – Consumo de cimento em kg por m³ de argamassa.

Tipo de argamassa	Uso ou aplicação	
	Interna	Externa
Assentamento de blocos	150-180	160-190
Chapisco	380-430	413-470
Emboço	160-180	180-210
Reboco	160-170	170-190
Camada única (Emboço paulista)	160-180	180-210
Assentamento	250-350	250-350

Fonte: Adaptado de Gomes e Neves (2002).

2.3 Aprendizado de máquinas na predição da resistência de misturas cimentícias

Os estudos envolvendo a determinação da resistência de misturas cimentícias vem sendo largamente utilizadas por pesquisadores por permitir à predição de resistência sem que seja necessário realizar o preparo da mistura bem como o tempo de cura necessário para a determinação da resistência.

Czarnecki *et al.* (2021) afirmam que o uso do método convencional para a determinação da resistência de compósitos cimentícios demanda o uso de laboratórios, são demorados e com um custo elevado, lembra ainda que a grande maioria desses ensaios é destrutiva, tornando assim a aplicação de compósitos onde há a adição de resíduos ineficientes, por apresentarem custo elevado e elevados períodos para sua realização.

A aplicação de algoritmos de aprendizado de máquinas (AM) não elimina a necessidade de dosagem em laboratório, sendo necessário a realização da caracterização dos insumos (aglomerantes, agregados, água, aditivos e adições), funcionando inicialmente como um método de aferição da resistência do traço obtido, acelerando assim a tomada de decisão quanto a utilização ou não do traço, onde os resultados preditos com melhor desempenho devem prosseguir para à realização de mistura e ensaio destrutivo, a fim de validar o resultado predito.

A aplicação de modelos de AM possibilita a determinação da resistência em idades iniciais como também em períodos mais longos de tempo, não apenas aos 28 dias (CZARNECKI *et al.*, 2021).

O uso de algoritmos de IA durante a fase experimental auxilia o laboratorista e, ou pesquisador, pois permite prever a resistência do traço, caso a mesma seja insatisfatória poderá ser realizada nova dosagem sem que se tenha o uso de insumos, tempo de cura e custo

com os ensaios. Obtendo predição de uma resistência satisfatória os procedimentos laboratoriais são seguidos conforme normatização.

A utilização de modelos de AM como ferramenta de controle de qualidade de cimentos permitiu um ganho de tempo nas análises de 92%, pois são obtidos resultados com precisão na predição de 95% com no máximo 2 dias de cura, enquanto do modo atual são necessários 28 dias para tal (NEGREIROS *et al.*, 2020).

As redes neurais artificiais (*Artificial Neural Network* - ANN) podem ser aplicadas tanto para a determinação da resistência à compressão ou flexão de argamassas com adição, apresentando coeficiente R^2 superior à 99% nos modelos tanto de resistência à compressão quanto de tração (ONYARI; IKOTUN, 2018). Rocha *et al.* (2020) obtiveram correlação de 96,8% na aplicação de um modelo de ANN para predição da resistência à compressão do concreto.

Salih *et al.* (2021) utilizaram abordagens de regressão linear e não linear, ANN e árvore de decisão (*Decision Tree* - DT), onde foram considerados os parâmetros que afetam diretamente na resistência à compressão da argamassa, incorporação de cinzas volantes, relação água/cimento, e cura, sendo obtido o coeficiente de correlação de 98,8 e 95,0% para os algoritmos de ANN e M5P-tree respectivamente.

Nazari e Sanjayan (2015) realizaram a modelagem da resistência à compressão de pastas geopoliméricas, argamassa e concretos utilizando algoritmos ANN e Máquinas de Vetor Suporte (*Support Vector Machine* - SVM) e realizaram a combinação do SVM com algoritmos meta-heurísticos, obtendo valor de R^2 de 86,91% para teste no algoritmo SVM combinado com o algoritmo de meta-heurística de otimização competitiva imperialista enquanto apenas o modelo de SVM teve um desempenho de R^2 de 71%, mostrando que a combinação entre o SMV e meta-heurísticas pode ser utilizada com resultados satisfatórios.

Asteris *et al.* (2021) avaliaram a utilização de algoritmos de AM para a predição da resistência de argamassas de cimento, foram avaliados o SVM, RF, Árvore de Decisão (DT), kNN e o AdaBoost, obtendo R^2 de 94,7 e 94,4% para os algoritmos Adaboost e RF, respectivamente, permitindo assim predizer os resultados.

Capítulo 3

APRENDIZADO DE MÁQUINAS

Nesse capítulo estão apresentados conceitos sobre o aprendizado de máquinas, definições teóricas acerca da teoria que engloba a área de estudo e alguns algoritmos de regressão empregados para a análise de dados.

3.1 Aprendizado de máquinas

O aprendizado de máquinas (AM) é uma das disciplinas básicas que compõem a inteligência artificial (IA) (RUSSEL; NORVIG, 2013). Teve a ampliação de seu uso decorrente do aumento da complexidade dos problemas de IA (FACELI *et al.*, 2011).

Luger (2005) afirma que o aprendizado é um dos requisitos para as aplicações da IA sendo um gargalo a construção de sistemas com a aquisição de conhecimento de forma natural. A obtenção de dados para resolução dos problemas de IA eram complexos, por depender da cooperação de profissionais técnicos da área da pesquisa, depender também subjetividade da interpretação, intuição do profissional, podendo interferir na qualidade dos dados (FACELI *et al.*, 2011; MONTAÑO, 2016).

A solução que é largamente adotada é a aplicação de uma quantidade mínima de conhecimento para aprendizado (LUGER, 2005). A grande quantidade de informação gerada mundialmente permite o acúmulo de dados para aplicação em modelos de AM, tornando cada vez mais precisa a resposta dos algoritmos.

Segundo Faceli *et al.* (2011), a grande possibilidade de aplicações aliada ao crescimento do poder de processamento computacional e algoritmos cada vez mais eficientes permite o crescimento da área.

Mitchell (1997, p.2) define o aprendizado de máquina como: “Diz-se que um programa de computador aprende com a experiência E com respeito a alguma classe de tarefas T e medida de desempenho P, se o seu desempenho nas tarefas em T, conforme medido por P, melhora com a experiência E”.

Os algoritmos de AM devem ter a capacidade de aprender com os dados informados mesmo estes apresentando lacunas ou inconsistências, possuindo assim a capacidade de extrapolar as hipóteses geradas com as informações do conjunto de dados para um novo conjunto de dados de teste (FACELI *et al.*, 2011).

Os algoritmos de AM possuem formas distintas para representação dos dados ou realização da busca sendo denominados *bias*, essas preferências servem para restringir o espaço de busca das hipóteses, sem o viés não haveria aprendizado (MITCHELL, 1997; FACELI *et al.*, 2011; MONTAÑO, 2016).

O aprendizado pode ser dividido conforme o paradigma adotado para a tarefa, Faceli *et al.* (2011) as define em dois tipos:

- Preditivas – tem como meta a obtenção de uma função (hipótese), para tal os dados de treinamento devem ter valores de entrada e saída;
- Descritivas – tem como meta explorar ou descrever os dados, tais algoritmos não fazem uso de valores de saída para aprendizado.

Com base nos paradigmas apresentados é possível determinar o tipo de aprendizado, supervisionado, não supervisionado e por reforço.

Russel e Norvig (2013) definem os diferentes tipos de aprendizado da seguinte forma:

- Aprendizagem não supervisionada – Nela o agente aprende a partir dos dados de entrada, a tarefa mais comum para esse tipo de aprendizagem é o agrupamento;
- Aprendizagem por reforço – Nela o agente aprende por meio de uma série de reforços, um exemplo seria em um jogo de tabuleiros em caso de vitória ganhar pontos, em caso de derrota não se ganharia nada;
- Aprendizagem supervisionada – Nela o agente observa exemplos de entrada e saída, aprendendo uma função capaz de mapear os valores de entrada e saída.

3.2 Tipos de aprendizado de máquinas

Quando se realiza uma busca sobre tipos de algoritmos de AM é possível encontrar uma grande quantidade de métodos de aprendizado para a indução da função em estudo. Observando o paradigma de aprendizado que é uma premissa básica para as técnicas de AM é interessante,

portanto, ao trabalho o estudo de algoritmos de modelo preditivo de regressão para que seja possível a indução da minimização das métricas de desempenho do modelo.

3.2.1 *k*-Vizinhos Próximos (*k*-Nearest Neighbour – *k*-NN)

É uma técnica de AM muito utilizada onde os algoritmos trabalham com a medida de distâncias, rotulando os dados de teste por proximidade aos dados de treinamento.

Mitchell (1997) cita que esse tipo de algoritmo é o mais simples de AM, onde os vizinhos de uma instância são definidos por meio da distância Euclidiana da instância para os vizinhos.

Faceli *et al.* (2011) apresentam que as medidas de distâncias Euclidianas podem ser representadas conforme Equação 3.1.


$$d(x_i, x_j) = \sqrt{\sum_{l=1}^n (x_i^l - x_j^l)^2} \quad (3.1)$$

Onde x_i e x_j são duas instâncias representadas por vetores no espaço \mathfrak{R}^d e x_i^l e x_j^l são elementos desses vetores, que correspondem aos valores da coordenada l (atributos).

A determinação de uma superfície de decisão é complexa, pois resultam em poliedros convexos com o centro de cada instância, onde os dados no interior de determinada instância pertencem a ela, o agrupamento dessas instâncias é chamado de *Células de Voronoi* gerando assim a superfície de decisão (MITCHELL, 1997; FACELI *et al.*, 2011; SHALEV-SHWARTZ; BEN-DAVID, 2014).

Faceli *et al.* (2011) apresentam a construção das *Células de Voronoi* como um conjunto de treinamento D , onde a célula no entorno do ponto $x \in D$ é definida como um conjunto de pontos onde a distância a x é a menor distância entre qualquer outro ponto de D . A Figura 3.1 apresenta as *Células de Voronoi* obtidas para $k = 1$.

Figura 3.1 – Limite de decisão 1-NN.



Fonte: Shalev-Shwartz e Ben-David (2014).

Conforme Mitchell (1997) e Faceli *et al.* (2011) o algoritmo de k -NN permite que com certa facilidade que ele seja adaptado para a aproximação de uma função de destino com um valor contínuo.

Em problemas de classificação o valor teste é classificado por meio da escolha da instância mais votada, $\hat{g}(x_t) \leftarrow \text{moda}(g(x_1), \dots, g(x_n))$, já em problemas de regressão basta o cálculo do valor médio entre os k exemplos de treinamento mais próximos, $\hat{g}(x_t) \leftarrow \text{média}(g(x_1), \dots, g(x_n))$, contudo, se a função a ser minimizada for o desvio absoluto utiliza-se a mediana $\hat{g}(x_t) \leftarrow \text{mediana}(g(x_1), \dots, g(x_n))$ (FACELI *et al.*, 2011).

No algoritmo k -NN são considerados os k vizinhos mais próximos do conjunto de treinamento para com o ponto x_t do conjunto de teste, o valor de k deve ser preferencialmente um valor ímpar, para evitar empates nos votos da determinação nos casos de classificação (FACELI *et al.*, 2011).

Pode ser empregada uma técnica de ponderação das distâncias dos k vizinhos de treinamento atribuindo peso maior aos mais próximos, possibilitando assim o uso de $k = n$, (FACELI *et al.*, 2011). Conforme Equações 3.2 e 3.3.

- Problemas de classificação, moda ponderada:

$$y_t = \arg \max_{c \in Y} \sum_{i=1}^n w_i I(c, y_i) \quad (3.2)$$

- Problemas de regressão, média ponderada:

$$y_t = \frac{\sum_{i=1}^n w_i y_i}{\sum w_i} \quad (3.3)$$

Onde para as equações acima:

$w_i = \frac{1}{d(x_t, x_i)}$, é o peso associado a instância de treino x_i ;

$I(a, b)$, é uma função que retorna 1 se $a = b$;

y_i é a classe da instância de treino x_i ;

c é a classe de maior moda ponderada.

Mitchell (1997) e Faceli *et al.* (2011) apresentam ainda pontos positivos e negativos quanto ao algoritmo k -NN:

Positivos:

- Simples de ser implementado e utilizado;
- Pode ser aplicado tanto em problemas complexos quanto problemas simples;
- Erro do classificador *Bayes* ótimo para um número infinito de objetos.

Negativos

- É um algoritmo do tipo *lazy* (lento);
- Necessita de uma quantidade maior de processamento computacional;
- Problemas com a dimensionalidade dos exemplos.

3.2.2 Máquina de Vetor Suporte (*Support Vector Machine* - SVM)

As máquinas de vetor de suporte pertencem à classe de algoritmos de otimização, juntamente com as redes neurais artificiais, pois visam minimizar o erro da função objetivo (FACELI *et al.*, 2011).

Podem ser observadas como características que se destacam no SVM: (1) uma fundamentação teórica consistente; (2) apresenta desempenho em aplicações práticas do conhecimento humano satisfatórios (LIMA, 2018).

Cristianini e Shawe-Taylor (2000) dizem que o algoritmo SVM apresenta bons resultados por obter hiperplanos de alta dimensão, otimizando assim os limites de separação dos grupos de classificação.

As SVM's têm aplicação tanto para problemas de separação de superfícies lineares quanto para superfícies não lineares, podendo ainda ser utilizado em problemas de regressão (MONTAÑO, 2016).

Faceli *et al.* (2011) dizem que as SVM foram desenvolvidas por Vapnik (1995), dando sequência em seus estudos iniciados anos antes.

Tem-se como necessidade para a obtenção de resultados satisfatórios do método a determinação de bons classificadores para que os mesmos consigam generalizar, permitindo uma orientação evitando assim o *overfitting* (CRISTIANINI; SHAWE-TAYLOR, 2000).

A SVM pode ser aplicada tanto para problemas de classificação quanto de regressão, apresentando bons resultados em ambas as aplicações, no trabalho será abordado apenas as técnicas de regressão.

Smola e Schölkopf (2004) em sua publicação elaboraram um manual teórico voltado para a aplicação de regressão por vetores de suporte (RVS), abordando que o método de vetor suporte foi desenvolvido para aplicações práticas na indústria, onde realizaram a seguinte consideração:

Tem-se um conjunto de dados de treino $d = \{(x_1, y_1) \dots, (x_n, y_n)\} \subset X \times \mathbb{R}$ onde X denomina a entrada ($X = \mathbb{R}^2$) e Y a saída. O objetivo do ϵ -SR (VAPNIK, 1995) é encontrar um $f(x)$ que resulte no máximo, um desvio ϵ em relação aos valores alvo y_i , logo, não se busca uma função exata, mas sim uma função com o desvio menor que ϵ (SMOLA; SCHÖLKOPF, 2004, FACELI *et al.*, 2011).

Podendo ser linearmente descrita a função conforme apresentado na Equação 3.4 (SMOLA; SCHÖLKOPF, 2004):

$$f(x) = (w \cdot x) + b \quad (3.4)$$

Onde $w \in X, b \in \mathbb{R}$


Para se obter a regularidade é necessária a busca de uma função com um w pequeno, uma maneira de se garantir tal condição é minimizar a norma, ou seja, $\|w\|^2$. Resultando assim em um problema de otimização, Equações 3.5 e 3.6 (FACELI *et al.*, 2011).

$$\text{Minimizar} = \frac{1}{2} \|w\|^2 \quad (3.5)$$

$$\text{Sujeita às restrições} \begin{cases} y_i - w \cdot x_i - b \leq \varepsilon_i \\ w \cdot x_i + b - y_i \leq \varepsilon_i \end{cases} \quad (3.6)$$

Deseja-se obter uma função linear que aproxime os pares de (x_i, y_i) com o ε mais preciso. Como resultado busca-se uma função linear onde todos os dados estejam contemplados no entorno de f , conforme área sombreada na Figura 3.2.

Figura 3.2 – Ilustração função de aproximação RVS.



Fonte: Faceli *et al.* (2011)

Smola e Schölkopf (2004) e Faceli *et al.* (2011) lembram ainda que em alguns casos não se obtém uma função de margem rígida, para tanto é permitida a existência de alguns erros, denominando-as de variáveis de folga, essas variáveis permitem que se tenha ruídos e *outliers* nos dados, proposta por (VAPNIK, 1995), ficando assim apresentada conforme Equações 3.7 e 3.8.

$$\text{Minimizar} = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^n \xi_i + \xi_i^* \right) \quad (3.7)$$

$$\text{Sujeita às restrições} \begin{cases} y_i - w \cdot x_i - b \leq \varepsilon_i + \xi \\ w \cdot x_i + b - y_i \leq \varepsilon_i + \xi^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (3.8)$$

Onde:

ξ_i, ξ_i^* representam as variáveis de folga não negativas;

C é a constante de *trade-off* que determina a planura de f e o quanto maior que ε os desvios podem ser, impondo um peso à minimização dos erros.

Como resultado tem-se um problema de otimização quadrático. A função objetivo sendo minimizada é convexa e os pontos que satisfazem as restrições formam um conjunto convexo, apresentando um único mínimo global (LORENA; CARVALHO, 2007).

A forma de solucionar esse tipo de problema é feita a introdução de uma função Lagrangiana, englobando as restrições e associando-os aos multiplicadores de Lagrange α_i , onde as derivadas parciais são nulas, substituindo as resultantes na equação Lagrangiana inicial, conforme Equações 3.9 e 3.10 (SMOLA; SCHÖLKOPF, 2004, LORENA; CARVALHO, 2007, FACELI *et al.*, 2011).

A forma dual é interessante por permitir a representação dos termos de produtos internos (FACELI *et al.*, 2011).

$$\text{Maximizar} = -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \quad (3.9)$$

$$\text{Sujeita às restrições} \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases} \quad (3.10)$$

Onde:

α_i, α_i^* representam as variáveis de Lagrange;

K é a função de Kernel que satisfaz as condições de Mercer, Quadro 3.1.

De forma simplificada as condições Kernel que atendam as condições de Mercer são caracterizadas por dar origem a matrizes positivas semi - definidas K , em que cada elemento K_{ij} é definido por $K_{ij} = K(x_i, x_j)$, para todo $i, j = 1, \dots, n$ (HERBRICH, 2001 *apud* LORENA; CARVALHO, 2007).

Quadro 3.1 – Funções de Kernel mais utilizadas.

Tipo de Kernel	Função $K(x_i, x_j)$	Parâmetros
Polinomial	$(\delta(x_i \cdot x_j) + \kappa)^d$	δ, κ e d
RBF	$\exp(-\sigma \ x_i - x_j\ ^2)$	σ
Sigmoidal	$\tanh(\delta(x_i \cdot x_j) + \kappa)$	δ e κ

Fonte: Faceli *et al.*, (2011).

A escolha do Kernel e dos parâmetros interfere no desempenho do classificador obtido, por definir a fronteira induzida, sendo um tipo de Kernel inicial o RBF (Hsu *et al.*, 2002 *apud* LORENA; CARVALHO, 2007).

3.2.3 Floresta Aleatória (*Random Forest* - RF)

O algoritmo de RF foi proposto como um método de aprimoramento do algoritmo de árvore de decisão, onde se utiliza da técnica de ensacamento (*bootstrap aggregating* ou *bagging*) dos dados (ARCHER; KIMES, 2008).

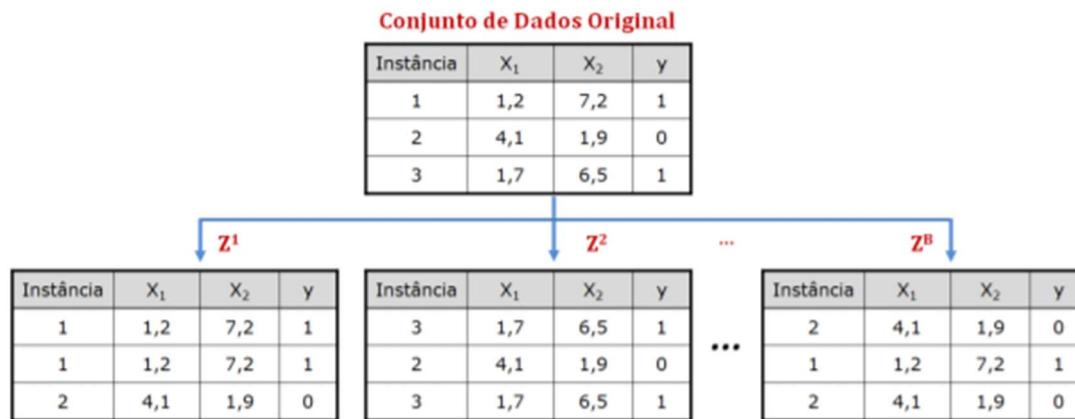
Faceli *et al.* (2011) afirmam que a árvore de decisão utiliza da estratégia de dividir para conquistar, onde o problema é dividido em subproblemas menores e esses subproblemas são novamente combinados, formando assim uma árvore, sendo definido formalmente como um grafo acíclico direcional, onde cada nó ou é *nó de divisão* ou é *nó de folha*. No *nó de divisão* são realizados testes lógicos baseados nos valores dos atributos e no *nó de folha* é rotulado com uma função.

A técnica do *bagging* proposta por Breiman (1996) gera um conjunto de dados por meio de amostragem de *bootstrap*, onde arvores são geradas por meio de uma seleção aleatória obtida em um conjunto de treinamento. Com o intuito de reduzir os erros de previsão do algoritmo de AM evitando o sobreajuste (SANTANA, 2020).

Alvarenga Júnior (2018) diz que a técnica *bootstrap* proposta por em 1979 por Efron é um método de reamostragem que tem por finalidade medir o desempenho do modelo.

Seja um conjunto de dados $D = (x_{1:n}, y_{1:n})$, a técnica cria amostras com instâncias aleatórias com base em D , formando assim novos conjuntos de dados $Z = (Z^1, Z^2, \dots, Z^B)$ do tamanho original, conforme mostrado na Figura 3.3.

Figura 3.3 – Técnica de *bootstrap* aplicada na criação de B conjunto de dados.



Fonte: Alvarenga Júnior (2018)

O método de *bagging* constrói múltiplas versões do preditor e as utiliza de forma agregada, onde a saída de uma determinada entrada é obtida por votação majoritária utilizando as respostas obtidas dos preditores, aplicando a técnica de *bootstrap* gerando Z^b amostras, ajustando assim um preditor $\hat{g}^{*b}(x)$, conforme apresentado na Equação 3.11 (MONTAÑO, 2016, ALVARENGA JÚNIOR, 2018).

$$\hat{g}(x_i) = \frac{1}{B} \sum_{b=1}^B \hat{g}^{*b}(x_i) \quad (3.11)$$

Cada árvore gerada aleatoriamente determina um resultado aleatório diferente com base no conjunto gerado, sendo calculada à média dos resultados, obtendo assim o valor predito pela floresta, diminuindo assim a variância do conjunto sem elevar o viés indutivo do conjunto com apenas uma árvore (MONTAÑO, 2016; ALVARENGA JÚNIOR, 2018).

O RF é definido como uma coleção de árvores estruturadas de classificadores, onde cada árvore lança um voto para o melhor valor de cada classe de entrada x (BREIMAN, 2001).

A floresta é organizada da seguinte forma $\{T_1(\theta_1), T_2(\theta_2), \dots, T_B(\theta_b)\}$, onde T_i é cada árvore e θ_b são as amostras bootstrap aleatorizada das variáveis, $mtry \times q$, onde apenas um número ($mtry$) dos parâmetros será escolhido para realizar os testes nos nós, onde são escolhidos por particionamento, o valor de $mtry$ é obtido por meio da Equação 3.12 em problemas de classificação e da Equação 3.13 para problemas de calibração, a partir de um

conjunto de atributos d , podendo variar de 1, ..., d e q é representa os dados utilizados no treinamento, onde aproximadamente 2/3 dos dados de treinamento são utilizadas para construir uma árvore, os 1/3 restantes são utilizados como avaliadores de performance do modelo (BREIMAN, 1996, SANTANA, 2020, ALVARENGA JÚNIOR, 2018), a Equação 3.14 descreve a saída do modelo.

$$mtry = \sqrt{d} \quad (3.12)$$

$$mtry = 0,333 \cdot d \quad (3.13)$$

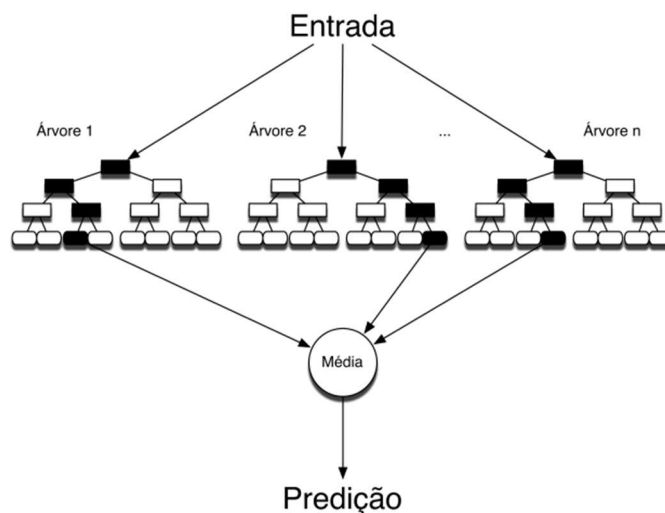
$$\hat{g}(x_i) = \frac{1}{B} \sum_{b=1}^B T(x_i, \theta_b) \quad (3.14)$$

Onde:

$mtry$ é o número de parâmetros analisados no nó;
 d é o de variáveis;
 T é cada árvore do modelo;
 θ é a amostra de bootstrap,

Um exemplo genérico de uma floresta aleatória é mostrado na Figura 3.4, onde os dados de entrada são aleatorizados para n árvores.

Figura 3.4 – Esquema de funcionamento de uma RF.



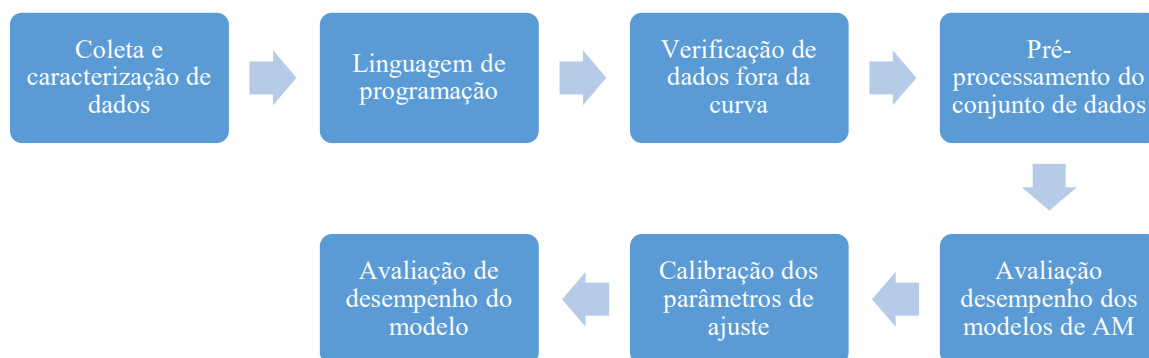
Fonte: Montaña (2016).

Capítulo 4

MATERIAIS E MÉTODOS

Neste capítulo está apresentada a metodologia utilizada para a predição da resistência a compressão de argamassas, seguindo diversos passos interdependes até a obtenção do melhor modelo. A Figura 4.1 mostra um fluxograma de todos os passos relacionados na predição da resistência de argamassas.

Figura 4.1 – Fluxograma das técnicas utilizadas para predição de resistência de argamassas.



Fonte: o autor.

4.1 Coleta de dados

O banco de dados foi obtido por meio de levantamento bibliográfico no periódico *Capes*, por meio do servidor da Universidade Federal de Goiás – Regional Catalão, nas bases de dados *SpringerLink* e *ScienceDirect* (Elsevier), *Google Acadêmico* e site de busca, utilizando as *strings* “mortar” e “substitution”, além dos equivalentes em português “argamassa” e “substituição” após a filtragem dos trabalhos obtidos os dados de consumo foram tabulados.

O banco de dados estruturado está apresentado no Apêndice A. É importante salientar que existem trabalhos que apresentam apenas um traço, uma resistência e, ou, diversas datas de resistência para um único traço, esses dados são referentes apenas ao traço de controle do respectivo trabalho, pois os materiais de substituição não enquadravam no grupo de variáveis selecionadas para esta pesquisa.

No levantamento dos dados foram considerados apenas consumos para produção de argamassa, logo não há diferenciação entre massas específicas de agregados bem como não há distinção na classe dos aglomerantes, tal separação tornaria a elaboração do banco de dados inviável.

Para o banco de dados foi considerada apenas a resistência à compressão como variável resposta. Na Tabela 4.1 são apresentados os valores mínimos e máximo referentes ao consumo de insumos, dias de cura e resistência à compressão levantados após a sumarização do banco de dados.

Tabela 4.1 – Consumo de insumos traços para a produção de 1 m³ de argamassa.

Dados	Valor Mínimo	Valor Máximo
Cimento (kg)	136,49	2616,67
Cal (kg)	0,00	1338,54
Areia Natural (kg)	0,00	5273,00
Areia Artificial/RCD (kg)	0,00	2250,00
RBMG (kg)	0,00	352,30
Aditivo plastificante (L)	0,00	10,60
Água (L)	102,92	1570,00
Cura (dias)	1	360,00
Resistência à compressão (MPa)	0,54	76,90

Fonte: o autor.

Analisando-se a Tabela 4.1 é possível notar que as areias de RCD foram agrupadas juntamente com as areias artificiais, pois o processo de obtenção da mesma se dá por britagem, logo é um agregado artificial, os resíduos de marmoraria (RBMG) são aplicados exclusivamente como substituição do cimento.

4.2 Linguagem de Programação

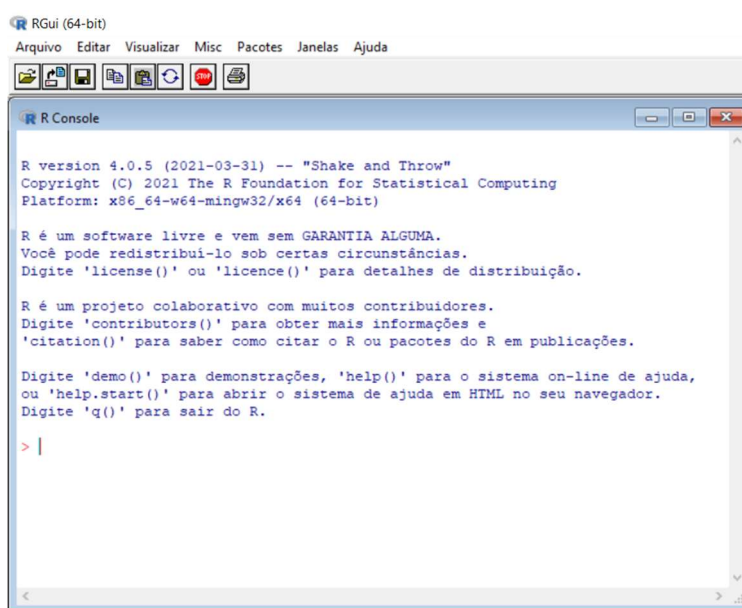
A linguagem de programação utilizada na realização dos cálculos é o R por ser um ambiente desenvolvido para cálculos estatísticos e análise de dados, fornece uma grande variedade de técnicas estatísticas e gráficas. Montañó (2016) afirma que é uma linguagem largamente utilizada por pesquisadores por possibilitar o desenvolvimento de aplicativos de análise de dados bem como estatísticos.

O R é projetado como uma linguagem computacional que permite ao usuário a edição e implementação de funções, permite a inclusão de pacotes adicionais. O que torna a linguagem

computacional extremamente interessante é permitir a edição e implementação de funções e permitir a inclusão de pacotes adicionais é que o R é um Software Livre atendendo aos termos de diretrizes da GNU *General Public License*.

Para a realização do processamento dos dados e validação do modelo foi utilizado o software R na versão 4.0.5, conforme Figura 4.2, onde foram baixadas e utilizadas as bibliotecas, 'readxl', 'tidyverse', 'coorplot', 'GGally', 'rpart', 'rpart.plot', 'caret', 'tidymodels', 'moments', 'caretEnsemble'.

Figura 4.2 – Pagina inicial Software R.



Fonte: R development Core Team (2009).

4.3 Verificação de dados fora da curva

De posse da matriz compostas pelos insumos constituintes dos traços e de suas respectivas resistências, verificou-se os pontos fora da curva (*outliers*) através do Algoritmo 4.1. Faceli *et al.* (2011) dizem que em grande parte dos conjuntos de dados há a presença de ruídos, dados incompletos e, ou inconsistentes, podendo afetar o desempenho do modelo.

Para a verificação de *outliers* foi realizada uma caracterização estatística descritiva completa do conjunto de dados, onde foram determinados os valores mínimo, máximo e amplitude dos valores de cada variável, posteriormente realizou-se a média aritmética e mediana das variáveis. Posteriormente foram determinados ainda o primeiro e o terceiro quartis, bem como o desvio padrão e variância do conjunto de dados. De posse dos valores obtidos para cada variável foi montado um gráfico de *boxplot* para que fosse possível observar os *outliers*

de cada variável, bem como uma tabela com a análise descritiva das variáveis. Este tipo de gráfico permite observar a distribuição e simetria dados e a visualização de eventuais dados discrepante (*outliers*) de uma forma mais simples FACELI *et al.*,2011; FÁVERO; BELFIORI, 2017).

Algoritmo 4.1: Algoritmo para verificação dos pontos fora da curva.

Entrada: *dados traço argamassa*

1 **para** cada variável **faça**

2 Análise descritiva da variável;

3 Remova *outliers*;

4 Plote um gráfico *boxplot* das variáveis;

5 Plote tabela análise descritiva das variáveis;

6 Plote um gráfico de correlação das variáveis;

7 **Saída:** conjunto de *dados brutos* sem pontos fora da curva.

4.4 Verificação da correlação das variáveis

Buscou-se um modo de se observar a relação de interdependência das variáveis do conjunto de dados, para tal visualização foi utilizado o modelo de correlação Pearson (ρ) é uma medida relação linear entre variáveis que pode variar de -1 a 1, (LIRA, 2004; CALLEGARI-JAQUES, 2003 *apud* LIRA, 2004; FÁVERO; BELFIORI, 2017), onde tem-se:

- Se $\rho > 0$, existe uma correlação positiva;
- Se $0 < \rho < 0,30$, existe uma fraca correlação;
- Se $0,30 < \rho < 0,60$, existe uma moderada correlação;
- Se $0,60 < \rho < 0,90$, existe uma forte correlação;
- Se $0,90 < \rho < 1$, existe uma correlação linear muito forte;
- Se $\rho = 1$, existe uma correlação perfeita positiva entre as variáveis;
- Se $\rho = 0$, não existe correlação entre as variáveis;
- Se $\rho < 0$, existe uma correlação negativa;
- Se $0 < \rho < -0,30$, existe uma fraca correlação negativa;
- Se $-0,30 < \rho < -0,60$, existe uma moderada correlação negativa;
- Se $-0,60 < \rho < -0,90$, existe uma forte correlação negativa;
- Se $-0,90 < \rho < -1$, existe uma correlação negativa linear muito forte;
- Se $\rho = -1$, existe uma correlação perfeita negativa entre as variáveis.

4.5 Pré-processamento do conjunto de dados

O pré-processamento dos dados tem por finalidade melhorar a qualidade dos mesmos minimizando eventuais problemas que dados inconsistentes podem causar ao modelo (FACELI *et al.*, 2011).

Castro e Ferrari (2016) apresentam técnicas de transformação de dados que possibilitam a melhora do desempenho do modelo quanto da existência de inconsistências no conjunto de dados, os autores apresentam:

- Padronização – visa resolver diferenças de unidades e escalas;
- Normalização – visa transformar dados de modo que fiquem mais apropriados à aplicação em algoritmos de mineração.

De posse do conjunto de dados, os mesmos foram tratados e utilizados de três formas, dados brutos (sem tratamento), tratados normalizados, onde as variáveis ficam com valores compreendidos entre 0 e 1 e padronizados, onde a média dos valores de cada variável é 0 e o desvio padrão é 1. Os tratamentos de normalização e a padronização, foram calculados conforme Algoritmo 4.2.

Quando aplicadas as técnicas de transformação (normalização e padronização) nas variáveis para permitir um maior aprendizado do algoritmo de AM (JAYALAKSHMI; SANTHAKUMARAN, 2011; SPLANIK *et al.*, 2015; JO, 2019; SINGH; SINGH, 2020; YARNOLD'; ALQURAIISHI, 2019; ISHWARAN; O'BRIEN, 2020), principalmente em grandes bancos de dados.

Algoritmo 4.2: Algoritmo para padronização e normalização dos dados.

Entrada: *dados brutos*

1 **para** cada variável **faça**

2 Padronizar dados – scale usando z-score;

3 Normalizar dados – min - max;

4 Análise descritiva da variável

5 Plote tabela análise descritiva das variáveis;

6 **Saída:** conjunto de *dados normalizados, dados padronizados*.

4.6 Avaliação de desempenho dos modelos de AM

Nesta seção será apresentada brevemente o fator motivante para a utilização das técnicas de AM de regressão apresentadas no Capítulo 3, cabe salientar que os algoritmos escolhidos podem ser utilizados para problemas de classificação. Para a implementação computacional dos métodos de AM foi utilizado o pacote ‘caretEnsamble’, pois o mesmo permite combinar e testar vários modelos de AM.

O k -NN foi escolhido por ser um dos algoritmos de AM mais simples, utiliza a medida de distâncias para a aproximação da função, apesar de ser um algoritmo do tipo *lazy*, por se ter um conjunto de dados relativamente pequeno não se espera ter um custo computacional muito elevado.

O SVM foi adotado por apresentar uma boa capacidade de generalização, por possibilitar a obtenção de um único mínimo global no processo de treinamento, possibilidade essa permitida pela convexidade do modelo. O uso da função de kernel radial permite também que o modelo gere hiperplanos ao invés de linearizar o modelo.

A escolha do RF para teste do modelo foi motivada pela capacidade de representação do modelo, pela capacidade que o modelo apresenta de não sofrer interferência de ruídos e *outliers*.

No Quadro 4.1 são apresentados os parâmetros de ajuste dos algoritmos analisados, onde os mesmos foram testados para os três tratamentos dos dados, sendo calculadas as métricas de desempenho dos modelos (R^2) e posteriormente comparado o desempenho dos mesmos, conforme mostrado no Algoritmo 4.3

Quadro 4.1 – Parâmetros de ajuste dos algoritmos.

Modelos	Parâmetros
k -NN	Nº de vizinhos (k)
SVM	Constante (c) Kernel tipo RBF (σ)
<i>Random Forest</i>	Nº de preditores ($mtry$)

Fonte: KUHN (2019).

Os parâmetros de calibração dos algoritmos não serão modificados para o processamento inicial, sendo apenas determinado para os três algoritmos a utilização de 80% dos dados para treinamento e 20% para teste.

Algoritmo 4.3: Algoritmo aprendido de máquinas.

Entrada: *dados brutos, dados padronizados, dados normalizados*

- 1 **para** *cada conjunto de dados faça*
 - 2 Dados treino 80%;
 - 3 Dados teste 20%;
 - 4 **para** *cada conjunto de dados faça*
 - 5 Avaliação algoritmo AM;
 - 6 Plote tabela R²avaliação do modelo;
 - 7 **Saída:** métrica de desempenho R² análise descritiva.
-

4.7 Calibração dos parâmetros de ajuste

Após a simulação e determinação do tratamento de dados que melhor descreva o modelo, prosseguiu a calibração dos parâmetros do RF, para o tratamento que apresentar melhor resultado de R².

Onde serão verificados separação dos dados entre treino e teste, variando o *split* (divisão dos dados) entre treino e teste de 70 a 90% com intervalos de 5%.

Uma técnica utilizada para que o modelo de AM preditivo se mantenha equilibrado, onde consiga ser treinado e aprenda os dados, mas que consiga generalizar para dados desconhecidos é a validação cruzada (CASTRO; FERRARI, 2016).

O conjunto de dados foi testado para dois métodos diferentes de validação por reamostragem, (k-fold – número de grupos e repeated k-fold – número de grupos com repetições) sendo os dados subdivididos em conjuntos com 5 e 10 grupos cada, além de testá-los com 0 e 5 repetições, nessas repetições o subconjunto desditado ao teste da validação será alterado aleatoriamente. No Algoritmo 4.4 foi realizada a validação cruzada, onde o melhor *split* e o melhor controle de validação cruzada serão os valores que apresentarem maior R² e menores MAE e RMSE.

Algoritmo 4.4: Algoritmo determinação melhor *split* e controle.

Entrada: *melhor tratamento dados*

- 1 **para** conjunto de dados **faça**
 - 2 Dados treino 70, 75, 80, 85 e 90%;
 - 3 Dados teste 30, 25, 20, 15 e 10%;
 - 4 **para** conjunto de dados **faça**
 - 5 Avaliação algoritmo AM escolhido;
 - 6 Validação Cruzada em grupos de dados 5 e 10;
 - 6 Repetições da validação em 0 e 5;
 - 7 Plote tabela R^2 , MAE e RMSE avaliação do *split* e controle;
 - 8 **Saída:** métrica de desempenho R^2 , MAE e RMSE análise descritiva.
-

Para dar continuidade na análise de melhores parâmetros para otimizar o modelo, antecipando que o melhor modelo de AM foi o RF, foi avaliado também a quantidade de árvores que melhor representam o modelo, permitindo assim a diminuição do erro médio, onde serão variadas de 200 a 1200 unidades com acréscimo de 100 árvores, conforme Algoritmo 4.5.

Algoritmo 4.5: Algoritmo determinação melhor número de árvores.

Entrada: *melhor tratamento dados, melhor split, melhor controle subconjuntos*

- 1 **para** conjunto de dados **faça**
 - 2 Número de árvores;
 - 3 Avaliação algoritmo RF;
 - 4 Plote gráfico MAE *versus* número de árvores avaliação do número de árvores;
 - 5 **Saída:** métrica de desempenho R^2 , MAE e RMSE
-

Com a determinação do melhor *split*, melhor controle de subdivisão das amostras e o número de árvores, o algoritmo RF será executado para a determinar também o número de variáveis (*mtry*), Algoritmo 4.6, analisadas nos nós, variando de 1 a 8, onde será escolhida a que apresentar o menor RMSE.

Algoritmo 4.6: Algoritmo determinação melhor *mtry*.

Entrada: *melhor tratamento dados, melhor split, melhor controle subconjuntos, número de árvores*

- 1 **para** conjunto de dados **faça**
 - 2 Número de *mtry*;
 - 3 Avaliação algoritmo RF;
 - 4 Plote gráfico RMSE *versus mtry*;
 - 5 **Saída:** métrica de desempenho RMSE
-

Realizado o ajuste de todos parâmetros de que possibilitem a melhora do desempenho do algoritmo de AM, o mesmo foi executado a fim de avaliar o desempenho do algoritmo RF com todos os parâmetros otimizados.

Será comparado o desempenho do modelo na predição da resistência de todos os traços do conjunto de dados estudado. Por fim será realizada a determinação da importância das variáveis no modelo.

4.8 Ferramentas de avaliação do desempenho do modelo

Aplicação de qualquer técnica de AM tem como função ser o mais precisa possível para o modelo de aproximação, para tal verificação e validação, faz-se necessária a utilização de ferramentas estatísticas, as métricas utilizadas foram aplicadas nos trabalhos de Czarnecki *et al.* (2021), Ozcan *et al.* (2017) Sevim *et al.* (2021), Salih *et al.* (2021) Asteris *et al.* (2021) e Armaghani e Asteris (2021) são:

4.8.1 Coeficiente de determinação

O coeficiente de determinação (R^2) descreve a fração da variância dos dados observados que podem ser explicadas pelo modelo, seu valor fica entre 0 e 1, quanto maior o valor melhor é a concordância entre o modelo e a observação, sendo calculado por meio da Equação 4.1.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.1)$$

Onde:

R^2 é o coeficiente de determinação;
 y_i é o valor medido experimental;
 \hat{y}_i é o valor estimado;
 \bar{y} é a média dos valores observados;
 n é o número de dados.

4.7.2 Raiz quadrada do erro médio

A raiz quadrada do erro médio (Root Mean Squared Error – RMSE) possui unidade, que é igual à dimensão dos valores observados e preditos, sendo calculado por meio da Equação 4.2.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.2)$$

Onde:

$RMSE$ é a raiz quadrada do erro médio;
 y_i é o valor medido experimental;
 \hat{y}_i é o valor estimado;
 n é o número de dados.

4.7.3 Erro absoluto médio

O Erro absoluto médio (Mean Absolute Error – MAE) assim como o RMSE possui igual dimensão a dimensão dos valores observados e preditos, sendo o MAE a média dos desvios. Quando comparados o RMSE dá um peso maior aos desvios grandes, já o MAE dá um peso igual a todos os desvios, sendo calculado por meio da Equação 4.3.

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (4.3)$$

Onde:

MAE é o erro médio absoluto;
 y_i é o valor medido experimental;
 \hat{y}_i é o valor estimado;
 n é o número de dados.

As métricas de avaliação do desempenho apresentas são utilizadas durante a execução do algoritmo dos itens 4.5 e 4.6, logo o resultado da avaliação de desempenho é o resultado obtido no item.

Capítulo 5

RESULTADOS E DISCUSSÕES

A seguir serão apresentados os resultados para os métodos de aprendizado de máquinas utilizados no trabalho, tendo como base o banco de dados apresentado no Apêndice A.

5.1 Caracterização dos dados

O banco de dados conta com 9 atributos, onde 8 variáveis são de entrada e 1 variável de resposta, durante o levantamento bibliográfico foram selecionados e catalogados 53 trabalhos científicos elaborados e publicados entre 2003 e 2021, onde foram obtidos 370 resultados, tal quantidade de resultados dá-se pela existência de diferentes traços utilizados em cada trabalho, bem como pelos resultados obtidos pelo rompimento dos corpos de prova (CP) em diferentes idades de cura, Apêndice A.

Diversos trabalhos de AM consultados apresentam conjuntos de dados variando de 196 a 1000 resultados como observado em Sevim *et al.* (2021), Mohammed *et al.* (2020), Armaghani e Asteris (2021) e Ghafor *et al.* (2020), cabe ressaltar que a grande variação do número de dados apresentados por trabalhos distintos é decorrente das diferentes adições presentes nas misturas das argamassas pesquisadas, como cinzas volantes, metakaolin e sílica ativa, podendo variar assim a quantidade de dados disponível na elaboração do banco de dados mostrando então que o conjunto de dados elaborado apresenta uma quantidade relevante de dados para verificação do modelo.

5.2 Verificação dos pontos fora da curva

A fim de se realizar uma análise descritiva completa dos dados nos modelos, os mesmos foram descritos estatisticamente de três formas distintas na Tabela 5.1 são apresentados os resultados quantitativos para os dados não tratados, dito brutos, onde é calculada a estatística descritiva conforme conjunto de dados.

Tabela 5.1 – Estatística descritiva dos dados brutos.

	Ci	Ca	AN	AR	RBMG	Adi	Ag	D	Res
Min	136,49	0,00	0,00	0,00	0,00	0,00	102,92	1,00	0,54
Q_1,25%	244,11	0,00	945,00	0,00	0,00	0,00	262,43	7,00	5,00
Mediana	450,00	0,00	1320,80	0,00	0,00	0,00	307,98	28,00	14,47
Q_3,75%	527,89	0,00	1534,44	426,75	0,00	0,00	315,00	28,00	31,88
Max	2616,67	1338,54	5273,00	2250,00	352,30	10,60	1570,00	360,00	76,90
Ampl	2480,18	1338,54	5273,00	2250,00	352,30	10,60	1467,08	359,00	76,36
Média	448,75	52,81	1197,58	301,50	10,35	0,39	321,94	31,88	20,63
SD	300,30	134,46	672,51	492,88	38,69	1,38	150,36	33,29	18,79
Var	90179,52	18078,94	452274,56	242934,10	1497,18	1,90	22608,88	1108,34	353,23
Assim	4,00	4,04	1,34	1,62	4,91	4,82	4,33	3,47	1,00
Curt	26,50	27,88	12,47	4,61	31,07	30,22	27,13	28,19	3,03
Soma	166036,86	19540,61	443104,68	111554,91	3828,84	143,76	119116,27	11794,00	7633,87
Nº dados	370,00	370,00	370,00	370,00	370,00	370,00	370,00	370,00	370,00
CV	66,92	254,60	56,16	163,48	373,91	354,60	46,71	104,44	91,09
IV	3,48	13,24	2,92	8,50	19,44	18,44	2,43	5,43	4,74
EP	15,61	6,99	34,96	25,62	2,01	0,07	7,82	1,73	0,98
IC_inf	418,049	39,067	1128,83	251,1128	6,3926	0,2477	306,5645	28,4723	18,7107
IC_sup	479,4475	66,558	1266,331	351,8867	14,3038	0,5294	337,3073	35,2791	22,5534
Moda	450,00	0,00	0,00	0,00	0,00	0,00	315,00	28,00	24,00

Ci = Cimento; Ca = Cal; NA = Agregado natural; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito; Adi = Aditivo; Ag = Água; D = Dias de cura; Res = Resistência à compressão; Min = Mínimo; Q_1,25% = Primeiro quartil; Q_3,75% = Terceiro quartil; Max = Máximo; Ampl = Amplitude; SD = Desvio padrão; Var = Variância; Assim = Assimetria; Curt = Curtose; Nº dados = Número de dados; CV = Coeficiente de variação; IV = índice de variação, EP = Erro padrão; IC_inf = Intervalo de confiança inferior; IC_sup = Intervalo de confiança superior.

Fonte: o autor.

Ao se analisar a Tabela 5.1 é possível notar que a moda para a variável dias é 28, não sendo por acaso, já que a resistência (fck) é medida aos 28 dias de cura da mistura, os ensaios realizados antes ou depois desta data são realizados para que seja possível traçar a curva de resistência da argamassa e em casos de ensaio para aplicação em obras.

Foi possível observar que a resistência média das argamassas é de 20,63 MPa, uma resistência considerável, ao se observar a relação água/cimento dos traços que apresentaram resistência superior à média é possível encontrar relações variando de 0,21 a 0,84, argamassas que apresentam resistência superior à média com 2 dias de cura onde o consumo de cimento é bastante elevado.


Ao observar a análise descritiva dos dados do cimento é assimétrico positivo, com coeficiente de assimetria igual a 4, com uma maior concentração de valores no terceiro quartil, podendo ser entendido que há um consumo maior de aglomerante cimentício nessa região, foi possível observar também que o consumo médio é de 448,75 kg, o valor máximo de consumo de cimento que foi 2616,67 kg pode ser entendido como um *outlier*, já que diverge bastante dos demais valores.

O coeficiente de variação de todas as variáveis é maior que 30% logo, há uma alta dispersão nos dados. A curtose de todas as variáveis é maior que 0, portanto tem-se uma distribuição mais afunilada que a distribuição normal.

O maior desvio padrão observado foi o da areia natural, que foi de 672,51 kg, demonstrando assim uma grande dispersão dos dados, o menor desvio padrão observado foi do aditivo plastificante que foi de 1,38 kg, seu consumo variou de 0,15 a 1,45% da massa de aglomerante.

Para uma visualização mais dinâmica dos dados do banco de dados foi elaborado um gráfico tipo diagrama de caixa (*boxplot*) a fim de proceder uma análise gráfica dos dados (Figura 5.1), possibilitando a visualização da distribuição dos dados brutos e identificação de outliers.

Figura 5.1 – Gráfico de *boxplot* dados brutos.



Ci = Cimento; Ag = Água; D = Dias de cura; NA = Agregado natural; Ca = Cal; Adi = Aditivo; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito; Res = Resistência à compressão.

Fonte: o autor.

Analisando-se a Figura 5.1 foi possível observar a existência de outliers nos atributos, a maior quantidade pode ser observada na cal, areia artificial, resíduos de marmoraria e água. É possível observar também que a areia natural é assimétrica negativa, já a areia artificial é assimétrica positiva. A areia natural apresenta a maior amplitude das variáveis máximo e mínimo, seguido pelo cimento, já a areia natural tem seu mínimo no primeiro quartil, que também coincide com a mediana.

O código foi elaborado para realizar a remoção dos *outliers*, conforme apresentado na Tabela 5.2 a análise descritiva simplificada contudo, ao se proceder avaliação do conjunto de dados, tal remoção prejudicaria o modelo, pois seriam complementemente removidas três variáveis (Cal, RBMG e Aditivo), com essa remoção haveria uma diminuição do número de traços, caindo de 370 para 141 traços, tornando inviável a análise de dados com as variáveis escolhidas para a análise, já que todos os dados de substituição seriam descartados, então os *outliers* foram mantidos.

Tabela 5.2 – Estatística descritiva dos dados brutos sem *outliers*.

	Ci	Ca	AN	AR	RBMG	Adi	Ag	D	Res
Min	190,00	0,00	135,00	0,00	0,00	0,00	196,69	1,00	1,12
Q_1,25%	450,00	0,00	1080,00	0,00	0,00	0,00	248,19	7,00	10,30
Mediana	450,00	0,00	1350,00	0,00	0,00	0,00	289,00	14,00	20,00
Q_3,75%	563,96	0,00	1477,13	202,50	0,00	0,00	315,00	28,00	36,00
Max	778,00	0,00	2061,74	837,82	0,00	0,00	379,00	28,00	67,00
Ampl	588,00	0,00	1926,74	837,83	0,00	0,00	182,31	27,00	65,88
Media	473,33	0,00	1308,16	131,78	0,00	0,00	283,70	16,79	24,41
SD	130,81	0,00	322,68	220,30	0,00	0,00	43,04	10,92	17,19
Var	17112,08	0,00	104123,65	48533,18	0,00	0,00	1852,08	119,19	295,53

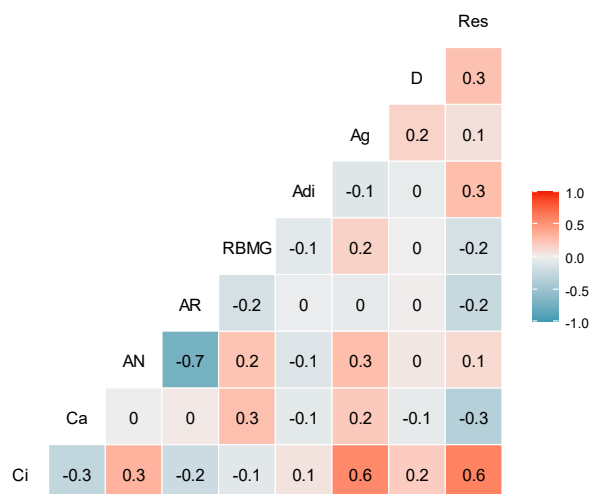
Ci = Cimento; Ca = Cal; NA = Agregado natural; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito; Adi = Aditivo; Ag = Água; D = Dias de cura; Res = Resistência à compressão; Min = Mínimo; Q_1,25% = Primeiro quartil; Q_3,75% = Terceiro quartil; Max = Máximo; Ampl = Amplitude; SD = Desvio padrão; Var = Variância.

Fonte: o autor.

5.3 Verificação de correlação das variáveis

Com o intuito de identificar o comportamento relacional das variáveis no modelo foi plotado o gráfico de correlação entre as variáveis dos dados, conforme mostra a Figura 5.2.

Figura 5.2 – Gráfico de correlação das variáveis.



Ci = Cimento; Ag = Água; D = Dias de cura; NA = Agregado natural; Ca = Cal; Adi = Aditivo; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito; Res = Resistência à compressão.

Fonte: o autor.

Ao ser realizada a análise da correlação na Figura 5.2 é possível observar uma correlação de 0,6 entre a água e o cimento. Zhang *et al.* (2021) em sua análise dos dados avaliou uma correlação positiva fraca entre o cimento e a água, superior a 0,2, logo quase inexistente.

Água e cimento são altamente correlacionáveis visto que todo o processo de dosagem de argamassa tem como critério base a relação água/cimento, pois essa relação interfere diretamente na resistência da mistura e na trabalhabilidade, conforme resultado apresentado na Figura 5.2.

Outras variáveis que apresentam correlação são os dias de cura com a resistência, como é esperado a resistência à compressão tende a aumentar com o passar dos dias de cura até a resistência máxima possível da mistura. Cheah *et al.* (2012), Apolinário (2014) e Ning *et al.* (2015) observaram em seus trabalhos um ganho de resistência de até 23% com idades superiores à 28 dias, Demir *et al.* (2018) observaram um ganho de resistência nas argamassas até 180 dias após a realização da mistura, no ensaio realizado com 360 dias o ganho de resistência foi de 0,18%, não apresentando ganho significativo com o acréscimo de 6 meses após o ensaio anterior, entendendo assim que a mistura alcançou a máxima resistência possível.

É possível observar que o agregado natural e o agregado artificial/RCD apresentaram correlação de -0,7, são, portanto, inversamente correlacionais, isso se dá porque o agregado artificial/RCD é utilizado em substituição ao agregado natural, quanto maior a quantidade de um agregado menor será a do outro.

O estudo permitiu observar que os materiais, resíduo de marmoraria, areia artificial e cal tem correlação inversa, -0,2, -0,2 e -0,3, respectivamente, com a resistência, logo quanto maior a quantidade desses materiais menor será a resistência da argamassa, sendo possível observar tal redução nos resultados obtidos por Moriconi *et al.* (2003), Pimentel *et al.* (2018), Marvila *et al.* (2019) e Agrawal *et al.* (2021).

5.4 Pré-Processamento do conjunto de dados

Nas Tabelas 5.3 e 5.4 são apresentadas as análises descritivas resumidas dos dados após a padronizados e normalização, respectivamente, dos mesmos visando diminuir a diferença de escala dos dados.

Tabela 5.3 – Estatística descritiva dos dados padronizados.

	Ci	Ca	AN	AR	RBMG	Adi	Ag	D	Res
Min	-1,0400	-0,3930	-1,7810	-0,6120	-0,2670	-0,2820	-1,4570	-0,9270	-1,0690
Q_1,25%	-0,6820	-0,3930	-0,3760	-0,6120	-0,2670	-0,2820	-0,3960	-0,7470	-0,8320
Mediana	0,0040	-0,3930	0,1830	-0,6120	-0,2670	-0,2820	-0,0930	-0,1160	-0,3280
Q_3,75%	0,2640	-0,3930	0,5010	0,2540	-0,2670	-0,28200	-0,0460	-0,1160	0,5980
Max	7,2190	9,5620	6,0600	3,9530	8,8380	7,4120	8,3000	9,8560	2,9940
Ampl	8,2590	9,9550	7,8410	4,5650	9,1050	7,6940	9,7570	10,7840	4,0630
Media	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
SD	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
Var	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000

Ci = Cimento; Ca = Cal; NA = Agregado natural; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito; Adi = Aditivo; Ag = Água; D = Dias de cura; Res = Resistência à compressão; Min = Mínimo; Q_1,25% = Primeiro quartil; Q_3,75% = Terceiro quartil; Max = Máximo; Ampl = Amplitude; SD = Desvio padrão; Var = Variância.

Fonte: o autor.

Tabela 5.4 – Estatística descritiva dos dados normalizados.

	Ci	Ca	AN	AR	RBMG	Adi	Ag	D	Res
Min	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
Q_1,25%	0,0434	0,0000	0,1792	0,0000	0,0000	0,0000	0,1087	0,0167	0,0584
Mediana	0,1264	0,0000	0,2505	0,0000	0,0000	0,0000	0,1398	0,0752	0,1824
Q_3,75%	0,1578	0,0000	0,2910	0,1897	0,0000	0,0000	0,1446	0,0752	0,4104
Max	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
Ampl	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
Media	0,1259	0,0395	0,2271	0,1340	0,0294	0,0367	0,1493	0,0860	0,2631
SD	0,1211	0,1005	0,1275	0,2191	0,1098	0,1300	0,1025	0,0927	0,2461
Var	0,0147	0,0101	0,0163	0,0480	0,0121	0,0169	0,0105	0,0086	0,0606

Ci = Cimento; Ca = Cal; NA = Agregado natural; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito; Adi = Aditivo; Ag = Água; D = Dias de cura; Res = Resistência à compressão; Min = Mínimo; Q_1,25% = Primeiro quartil; Q_3,75% = Terceiro quartil; Max = Máximo; Ampl = Amplitude; SD = Desvio padrão; Var = Variância.

Fonte: o autor.

5.5 Avaliação de desempenho dos modelos de AM

A conclusão do pré-processamento dos dados possibilitou à aplicação dos modelos de aprendizado de máquina, sendo avaliada a divisão dos dados entre treinamento e teste para os 3 algoritmos testados (k-NN, SVM e RF), a divisão aleatória dos dados foi de 80% para treinamento e 20% para teste. Diversos trabalhos de AM como Asteris *et al.* (2021), Marangu (2020), Marani e Nehdi (2020) e Lima *et al.* (2017) utilizam essa divisão dos dados. A avaliação dos modelos foi realizada com 9 variáveis (8 de entrada e 1 de saída), não sendo realizadas modificações nos parâmetros dos algoritmos.

Após a aplicação dos modelos de predição (k-NN, SVM, RF) para os três pré-processamentos (bruto, normalizados e padronizados) o mesmo é verificado quanto ao seu desempenho, onde é verificado o coeficiente de determinação (R^2) para os modelos de regressão, conforme apresentados nas Tabelas 5.5, 5.6 e 5.7.

Tabela 5.5 – Coeficiente de determinação dados brutos.

	Min	1st Qu	Median	Mean	3rd Qu	Max
RF	0,8160	0,8494	0,8546	0,8630	0,8668	0,9280
k-NN	0,5764	0,5948	0,6535	0,6694	0,7080	0,8145
SVM	0,6337	0,6458	0,6800	0,6794	0,7126	0,7251

Fonte: o autor.

Tabela 5.6 – Coeficiente de determinação dados padronizados.

	Min	1st Qu	Median	Mean	3rd Qu	Max
RF	0,8427	0,8494	0,8918	0,8786	0,9008	0,9084
k-NN	0,5961	0,6294	0,6471	0,6506	0,6514	0,7288
SVM	0,6529	0,6555	0,6631	0,6799	0,6859	0,7423

Fonte: o autor.

Tabela 5.7 – Coeficiente de determinação dados normalizados.

	Min	1st Qu	Median	Mean	3rd Qu	Max
RF	0,8483	0,8541	0,8753	0,8752	0,8853	0,9129
k-NN	0,6067	0,6310	0,6463	0,6732	0,6711	0,8111
SVM	0,6340	0,6751	0,6773	0,7035	0,7592	0,7720

Fonte: o autor.

A análise realizada com os modelos de AM que apresenta melhor generalização foi o RF, apresentando um R^2 médio de 86,30, 87,86 e 87,52% para dados brutos, padronizados e normalizados, respectivamente. Enquanto o k -NN retornou 66,94, 65,06 e 67,32% para os tratamentos, brutos, padronizados e normalizados, respectivamente. O SVM apresentou um desempenho superior ao k -NN para os tratamentos avaliados, brutos, padronizados e normalizados de 67,94, 67,99 e 70,35%, respectivamente, apresentando ainda um menor desempenho quando comparado ao RF. A baixa capacidade de generalização pode ser observada principalmente no k -NN demonstrando a limitação do método, pois o método é considerado um algoritmo de AM mais simples.

Asteris *et al.* (2021) em seu trabalho observou também que o desempenho dos algoritmos k -NN (88,07%) e SVM (37,86%) foram inferiores ao RF (97,68%) quando se avalia o coeficiente de determinação para o treino do modelo, cabe observar que o desempenho obtido pelo algoritmo k -NN foi superior ao SVM, divergindo assim dos resultados obtidos no modelo em estudo.

A diferença do R^2 médio no algoritmo RF entre os dados brutos *versus* normalizados e brutos *versus* padronizados foi inferior, de 1,2 e 1,6%, respectivamente, de tal forma adotou-se para a continuidade dos testes considerando-se RF utilizando-se dados brutos (sem tratamentos).

5.6 Calibração dos parâmetros de ajuste

O RF mesmo apresentando o melhor resultado na simulação permite ainda que seus parâmetros sejam otimizados, modificando assim a divisão de utilização de dados para treinamento e teste, método de controle (validação cruzada), quantidade de árvores e o número de variáveis avaliadas nos nós.

5.6.1 Determinação da separação entre treino e teste e método de controle

No estudo são observados para a determinação da melhor calibração o coeficiente de terminação (R^2) e a raiz do erro quadrado médio (RMSE), conforme apresentado nas Tabelas 5.8, 5.9, 5.10 e 5.11, onde foram avaliados para os dados brutos, para a determinação do melhor divisão entre treino e teste, foi ainda realizada uma validação cruzada onde os dados de entrada foram divididos em 5 e 10 subconjuntos de dados, realizando ainda 0 e 5 repetições para cada subconjunto.

Tabela 5.8 – RF para dados brutos controle = 5.

MAE

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	4,25309	4,55301	5,11642	5,03923	5,61707	5,65657
75/ 25	4,01743	4,10820	4,58948	4,73476	4,73208	6,22660
80/ 20	3,22684	4,13096	4,36069	4,29542	4,75219	5,00640
85/ 15	3,06506	3,30275	4,13327	4,00107	4,39268	5,11158
90/ 10	3,50155	3,67174	4,17491	4,10306	4,47157	4,69554

RMSE

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	6,86865	7,06027	7,65315	8,08013	8,68625	10,13233
75/ 25	5,89448	6,49011	7,22324	7,78228	8,86178	10,44178
80/ 20	4,78894	6,12794	6,66027	7,19126	8,53694	9,84223
85/ 15	4,72841	5,78327	6,57308	6,52629	6,66751	8,87917
90/ 10	5,68295	6,29044	6,86178	6,79604	7,47498	7,67006

R²

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	0,73972	0,79967	0,83144	0,82672	0,86037	0,90241
75/ 25	0,73710	0,81238	0,85409	0,82998	0,87145	0,87488
80/ 20	0,79325	0,79867	0,87821	0,85841	0,88892	0,93301
85/ 15	0,78810	0,85938	0,90679	0,88180	0,91660	0,93812
90/ 10	0,81135	0,86685	0,88001	0,87331	0,90398	0,90435

MAE = Erro médio quadrado; RMSE = Raiz do erro médio quadrado, R² = coeficiente de determinação; Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor.

Tabela 5.9 – RF para dados brutos controle = 10.

MAE						
Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	3,7945	3,8860	4,3634	4,4175	4,7167	5,4579
75/ 25	2,9074	3,6074	4,0936	4,1951	4,7782	5,6704
80/ 20	3,4778	3,939792	4,1015	4,1647	4,4600	4,8147
85/ 15	2,5288	3,1426	3,8403	3,9856	4,8135	6,0360
90/ 10	3,0260	3,5156	3,9511	4,1031	4,4795	6,0328

RMSE						
Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	5,2956	6,0707	7,0494	7,1408	8,0173	9,8315
75/ 25	4,4043	5,4518	6,3816	6,5695	8,1475	8,6741
80/ 20	5,4709	6,1922	6,6142	7,0365	7,6427	10,1753
85/ 15	4,1502	5,3487	6,3842	6,4288	7,4675	9,9771
90/ 10	4,5226	5,6181	6,4679	6,6958	7,2487	10,5883

R ²						
Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	0,7197	0,8446	0,8929	0,8726	0,9154	0,9367
75/ 25	0,7678	0,8559	0,8978	0,8885	0,9314	0,9693
80/ 20	0,7628	0,8203	0,8634	0,8611	0,9029	0,94213
85/ 15	0,7577	0,8538	0,8799	0,8807	0,9119	0,9636
90/ 10	0,6906	0,8528	0,8875	0,8745	0,9163	0,9621

MAE = Erro médio quadrado; RMSE = Raiz do erro médio quadrado, R² = coeficiente de determinação; Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor.

Tabela 5.10 – RF para dados brutos controle = 5 e repetições = 5.

MAE

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	2,8374	4,2770	4,6415	4,6766	5,1535	6,1507
75/ 25	3,1402	4,0430	4,5523	4,5024	4,9873	5,9800
80/ 20	3,2529	3,9098	4,6122	4,4433	4,8999	5,6176
85/ 15	3,1228	3,8531	4,1302	4,2550	4,4675	5,8828
90/ 10	3,1943	4,0028	4,3618	4,3867	4,7986	5,3131

RMSE

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	4,4932	6,4664	7,5048	7,6143	8,4710	11,1693
75/ 25	4,5622	6,1583	7,2748	7,0267	7,8225	9,3213
80/ 20	4,8896	6,4662	7,3314	7,3108	8,1034	9,3512
85/ 15	5,4682	6,2058	6,6986	6,9985	7,5408	10,0493
90/ 10	5,0412	6,4756	7,0347	7,0604	7,6616	8,7734

R²

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max
70/ 30	0,6786	0,8117	0,8591	0,8477	0,8905	0,9489
75/ 25	0,7645	0,8337	0,8559	0,8613	0,8956	0,9328
80/ 20	0,7343	0,8135	0,8526	0,8456	0,8756	0,9417
85/ 15	0,7655	0,8512	0,8763	0,8687	0,9018	0,9426
90/ 10	0,7880	0,8495	0,8608	0,8661	0,8948	0,9400

MAE = Erro médio quadrado; RMSE = Raiz do erro médio quadrado, R² = coeficiente de determinação; Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor.

Tabela 5.11 – RF para dados brutos controle = 10 e repetições = 5.

MAE

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max,
70/ 30	2,4855	3,6846	4,4335	4,4423	5,1121	6,9478
75/ 25	2,5941	3,6330	4,2041	4,2732	4,7662	6,3999
80/ 20	2,3304	3,5479	4,1709	4,2974	5,0304	6,7474
85/ 15	2,6431	3,5655	4,2307	4,1693	4,6364	6,0571
90/ 10	2,5804	3,3563	3,8824	3,9992	4,6639	5,8990

RMSE

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max,
70/ 30	3,7402	5,6271	6,8722	7,1036	8,2814	12,7621
75/ 25	3,5725	5,2924	6,3812	6,6648	7,8572	11,0414
80/ 20	3,3847	5,6251	6,8769	7,0306	8,3889	11,0156
85/ 15	4,2148	5,8604	7,2346	6,8401	7,7437	9,8943
90/ 10	3,4820	5,3061	6,5179	6,5771	7,7341	10,6568

R²

Treino/ Teste	Min	1st Q	Median	Mean	3rd Q	Max,
70/ 30	0,6066	0,8117	0,8840	0,8644	0,9216	0,9647
75/ 25	0,6791	0,8318	0,8914	0,8735	0,9355	0,9683
80/ 20	0,5952	0,7927	0,8951	0,8564	0,9329	0,9662
85/ 15	0,6779	0,8447	0,8786	0,8727	0,9167	0,9570
90/ 10	0,6779	0,8498	0,8897	0,8795	0,9249	0,9778

MAE = Erro médio quadrado; RMSE = Raiz do erro médio quadrado, R² = coeficiente de determinação; Split = Separação treino; Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.
Fonte: o autor.

Foi, portanto, obtida a calibração ótima para o melhor *split* a divisão 85% dos dados para treinamento e 15% para teste, com 10 subconjuntos de dados, sem repetição, por apresentar os melhores valores de R² e RMSE, 88,07% e 6,4288 MPa, respectivamente, conforme pode ser observado na Tabela 5.9, Ozcan *et al.* (2017) utilizaram o *split* em 85 e 15% para treino e teste respectivamente e obtiveram um R² de 0,9639 para o modelo no teste.

Asteris *et al.* (2021) realizaram o particionamento entre treino e teste 80 e 20% e concluíram em seu trabalho que a divisão dos subconjuntos apresenta melhores resultados se o conjunto de dados for dividido em um número maior que 5 subconjuntos, afirmação essa que pode ser observada no presente estudo. Sun *et al.* (2019) e Zhang *et al.* (2021) utilizaram o particionamento em 70% e 30% respectivamente para treino e teste, os autores também utilizaram a divisão dos dados em 10 subconjuntos na validação cruzada dos dados de treino.

5.6.2 Determinação da quantidade de árvores

Outro fator importante para a calibração do modelo é a determinação da quantidade de árvores do modelo, pois uma quantidade pequena de árvores resultará num RMSE elevado. Svetnik *et al.* (2003) dizem que 500 árvores são suficientes para estabilizar o erro, motivo pelo qual foi realizada a verificação do algoritmo variando a quantidade de árvores de 200 a 1200 árvores para os dados brutos, conforme Tabela 5.12.

Tabela 5.12 – Quantidade de árvores para dados brutos.

MAE

Árvores	Min	1st Q	Median	Mean	3rd Q	Max
200	3,3315	3,8195	3,9498	4,1917	4,5715	5,3310
300	2,6562	3,6966	3,9677	3,9550	4,3587	5,2087
400	2,9931	3,8023	3,9705	4,1955	4,5825	5,8144
500	3,0120	3,3252	4,0293	4,2058	4,9872	5,7646
600	3,2497	3,8773	4,2980	4,1831	4,4866	5,3080
700	3,2106	3,6173	4,1686	4,1684	4,7109	5,2616
800	2,6169	3,7623	3,9170	4,0913	4,7806	5,3571
900	1,9791	3,6551	4,1887	4,0961	4,9121	5,8179
1000	3,0228	3,6463	4,1231	4,1600	4,2829	5,5468
1100	2,4585	3,4419	4,1486	4,0484	4,4981	5,7086
1200	2,8366	3,5684	4,1818	4,2351	4,9540	5,5677

RMSE

Árvores	Min	1st Q	Median	Mean	3rd Q	Max
200	5,1646	6,1244	6,5755	6,7936	7,7213	8,8053
300	3,7486	5,9401	6,5359	6,5184	7,3000	9,1548
400	4,3523	6,0097	6,9856	6,8532	7,3687	10,1494
500	4,4919	5,3504	6,4791	6,6570	7,3039	9,9544
600	4,9815	5,9773	6,6529	6,7938	7,9026	8,4114
700	4,7554	5,2183	7,1473	6,6506	7,51067	8,7229
800	4,2197	5,8472	6,2492	6,5627	7,7825	8,8503
900	3,3542	5,0641	6,5862	6,3601	7,3130	9,8088
1000	4,6304	5,6643	6,6652	6,6859	7,6542	8,5097
1100	3,9514	5,6165	6,4782	6,5413	7,4750	10,1507
1200	4,5850	5,2176	6,1298	6,6874	8,1056	9,3621

R²

Árvores	Min	1st Q	Median	Mean	3rd Q	Max
200	0,7995	0,8356	0,8841	0,8714	0,9051	0,9233
300	0,7505	0,8570	0,8851	0,8767	0,9001	0,9555
400	0,6870	0,8348	0,8938	0,8676	0,9212	0,9448
500	0,6006	0,8592	0,8895	0,8646	0,9136	0,9428
600	0,7660	0,8159	0,8941	0,8712	0,9217	0,9392
700	0,7540	0,8075	0,9063	0,8715	0,9294	0,9370
800	0,7592	0,8395	0,8867	0,8755	0,9116	0,9606
900	0,7182	0,8613	0,8768	0,8831	0,9487	0,9670
1000	0,7302	0,8130	0,8839	0,8672	0,9277	0,9675
1100	0,6784	0,8622	0,8920	0,8751	0,9204	0,9481
1200	0,7623	0,8072	0,8937	0,8734	0,9247	0,9811

MAE = Erro médio quadrado; RMSE = Raiz do erro médio quadrado, R² = coeficiente de determinação; nrtrees = Número de árvores; Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor.

Selecionando o número de árvores que apresentasse o maior R^2 e o menor RMSE, conforme apresentado na Tabela 5.12, obtendo-se assim a quantidade de árvores 900 para os dados brutos, sendo necessário assim uma quantidade maior de árvores a diminuição do erro quando se comparado com a quantidade apresentada na literatura, Sun *et al.* (2019) avaliaram em seu modelo um número de árvores entre 1 e 10 e obtiveram que o modelo com 8 árvores apresenta um melhor desempenho, Zhang *et al.* (2021) em seu modelo avaliaram que o número de árvores que resultaria no valor ótimo seria de 78 unidades, cabe ressaltar quem ambos os trabalhos utilizaram o algoritmo RF combinado com um algoritmo meta-heurístico onde o algoritmo de antena de besouro ajusta os parâmetros do algoritmo de AM, podendo ser avaliado como a razão da baixa quantidade de árvores utilizadas nos trabalhos..

5.6.3 Determinação no número de variáveis avaliadas nos nós

A determinação do número de variáveis avaliadas foi realizada pois possibilita assim verificar se a quantidade estipulada pelo modelo é suficiente, possibilitando assim um melhor resultado, para tal foi realizada a determinação do *mtry* que apresentasse um menor erro (RMSE), conforme Tabela 5.13, onde os melhores resultados dos parâmetros calculados anteriormente são utilizados na determinação do número de variáveis.

Tabela 5.13 – Avaliação no número de variáveis avaliadas por nó.

<i>mtry</i>	RMSE	R^2	MAE
1	9,6209	0,8033	7,2422
2	7,3302	0,8603	4,9127
3	6,8314	0,8728	4,3585
4	6,7346	0,8734	4,1607
5	6,7471	0,8712	4,1059
6	6,7857	0,8687	4,0805
7	6,9088	0,8629	4,1177
8	7,02241	0,8570	4,1920

MAE = Erro médio quadrado; RMSE = Raiz do erro médio quadrado, R^2 = coeficiente de determinação; *mtry* = Número de variáveis avaliadas.


Fonte: o autor.

O *mtry* que melhor avalia o modelo é o com 4 variáveis avaliadas por nó, pois resulta no menor RMSE conforme pode ser observando na Tabela 5.13. Sun *et al.* (2019) e Zhang *et al.* (2021) avaliaram que o número mínimo de variáveis para estar no nó folha é 1, sem ao menos uma variável o nó não realizaria nenhuma avaliação. Para o modelo em estudo apenas

uma variável por nó resulta no maior erro possível para o modelo, podendo levar o modelo a avaliar apenas a variável mais importante.

A Figura 5.3 apresenta a importância das variáveis para o desempenho do modelo onde é mostrado o ranqueamento percentual de cada variável

Figura 5.3 – Importância das variáveis no desempenho do modelo.



Ci = Cimento; Ag = Água; D = Dias de cura; NA = Agregado natural; Ca = Cal; Adi = Aditivo; AR = Agregado artificial; RBMG = Resíduo do beneficiamento de mármore e granito.

Fonte: o autor.

É possível observar que o cimento foi a variável mais importante com pontuação igual a 100%, seguido pela variável água e a variável dias de cura. As análises realizadas por Sun *et al.* (2019) analisaram que a variável dias de cura é a mais importante com um score 1,4170, já a variável cimento aparece em 6º lugar com 0,5231 de importância, a variável água com 0,9194 ocupa a terceira colocação no ranqueamento. Zhang *et al.* (2021) obtiveram em seu ranqueamento como variável mais importante os dias de cura com 35%, a variável cimento ficou em 5º lugar com 8% de importância, já a variável água apresentou uma importância de 12% ocupando o terceiro lugar. Cabe ressaltar que os trabalhos trataram sobre predição de resistência para concreto.

Ozcan *et al.* (2017) observaram também que a variável de entrada mais importante para predição das argamassas foi dias de cura com aproximadamente 0,9, a variável cimento


apareceu em terceiro lugar com uma importância de aproximada de 0,002. O presente estudo observou que o determinante na obtenção de resistência das argamassas são as variáveis cimento e água, posteriormente a idade, uma variável que para o modelo fica em terceiro lugar com mais de 38%.

5.7 Avaliação do algoritmo *Random Forest* após calibração dos parâmetros

O algoritmo do modelo foi novamente executado realizando a substituição dos parâmetros anteriormente determinados e avaliando assim o desempenho do modelo final com a substituição de todos parâmetros otimizados.

Durante a avaliação do modelo é possível analisar a correlação entre os valores de resistência reais e os preditos mostrada na Figura 5.4.

Figura 5.4 – Resistência à compressão real *versus* predita.



Fonte: o autor.

O gráfico permite observar que os dados se agrupam entorno do ajuste ideal (reta), apresentando variação na determinação da resistência foi menor que 30% em 82,70% dos resultados. É possível observar também que há um melhor ajuste no gráfico para resistências menores.

Analisando-se o banco de dados a fim de observar se haveria alguma variável responsável pela ocorrência de uma variação da determinação superior aos 30% não foi observado nenhuma que teria ligação direta com a ocorrência, tal análise possibilitou observar que 9 traços apresentaram uma variação elevada para todas as idades, nesse grupo haviam traços em que foi empregado a cal na mistura, bem com haviam traços sem a adição, mostrando assim que o emprego da cal não é determinante no erro existente.

Na Tabela 5.14 é apresentado um resumo do desempenho do algoritmo na predição com o particionamento dos dados para treino e teste, 85 e 15%, respectivamente, com divisão de 10 subconjuntos, utilizando 900 árvores e analisando 4 variáveis aleatórias por nó.

Tabela 5.14 – Resumo final modelo RF parâmetros ajustados.

Dados	RMSE	R ²	MAE
Treino	3,5970	0,9620	2,1649
Teste	7,4217	0,8694	4,6438

Fonte: o autor.

Os valores de R² obtidos no modelo com parâmetros ajustados foram de 96,20% para treino e 86,94% para teste, os resultados permitem observar que a modificação dos parâmetros de ajuste do algoritmo de AM apresentou uma melhora no modelo, visto que o valor do coeficiente de determinação do modelo aumentou 9,90% no treino, para quando observado o resultado obtido com os parâmetros ajustados automaticamente pelo modelo.

Ozcan *et al.* (2017) observaram em seu trabalho um R² de 96,39% para teste, Asteris *et al.* (2021) observaram um R² de 94,39% para teste, ambos os trabalhos apresentaram desempenho superior ao modelo estudado que foi de 86,94%, contudo, o coeficiente de determinação é satisfatório para os modelos, já que cada resultado obtido é referente à um conjunto de dados distinto, cabe lembrar que para o modelo em análise não foram retirados os *outliers* para validação do mesmo, podendo assim diminuir o desempenho do mesmo.

Asteris *et al.* (2021) em seu trabalho obteve valores para a raiz quadrada do erro médio de 3,36 e 5,20 MPa para treino e teste, respectivamente. Sun *et al.* (2019) obtiveram valores de RMSE de 2,24 MPa para treinamento e 3,90 MPa para teste. Os valores de RMSE obtidos para o modelo ajustado foram relativamente pequenos, 3,60 e 7,42 MPa para treino e teste respectivamente, sugerindo assim um ajuste desejável do modelo, sem *underfitting* e *overfitting*, conclusão semelhante à obtida nos trabalhos consultados.

Capítulo 6

CONSIDERAÇÕES FINAIS

Com base na revisão bibliográfica, pode-se dizer que é possível aplicar o aprendizado de máquinas como ferramenta de predição da resistência de argamassas e implementá-la de maneira eficaz. Os resultados obtidos foram coerentes com os resultados obtidos na literatura.

Além disso, o estudo possibilitou verificar que o pré-processamento do conjunto de dados interfere no desempenho do modelo, contudo, não é um fator determinante no desempenho, pois resultam em resultados relativamente semelhantes, considerando o banco de dados analisado e métodos testados

Em relação aos algoritmos utilizados, pode-se concluir que o aprendizado de máquinas é uma ótima ferramenta na análise de problemas de predição como este, pois possibilita a resolução com rapidez, possibilitando ainda a redução de custo e tempo de trabalho laboratorial para a determinação da resistência à compressão de argamassa.

Foi possível observar que a calibração dos parâmetros do algoritmo Floresta Aleatória quando ajustados para o modelo resultam numa melhora desempenho do modelo de 9,90%, elevando o desempenho de 86,30% com parâmetros aleatórios para 96,20% para os parâmetros ajustados.

Vale destacar que a metodologia, apesar de trabalhosa devido à grande quantidade de dados a serem levantados e tratados, torna-se um processo muito rápido através do uso do algoritmo, facilitando a predição da resistência à compressão para dosagens de bancada. Desse modo, pode-se concluir que o modelo aplicado nesse trabalho atingiu o objetivo do trabalho e é satisfatório.

No entanto, ressalva-se que é necessária uma atualização constante do banco de dados para que assim obtenha-se um modelo cada vez mais preciso de predição, bem como para validação.

Por fim, conclui-se que o AM é uma ferramenta de cálculo prática na predição da resistência de argamassas, principalmente se aplicada durante o processo experimental, pois

permite que apenas sejam realizados o processo de mistura para os traços com melhor característica de resistência, diminuindo ainda custos com a realização do rompimento dos corpos de prova, podendo ser realizado o processo de dosagem e obtenção da resistência apenas para os traços que forem mais interessantes, pois entende-se que a AM é uma ferramenta que deve ser adotada em conjunto aos procedimentos normatizados.

O melhor modelo foi o RF, e após a otimização dos parâmetros teve sua calibração/configuração sendo: do particionamento dos dados entre treino e teste de 85 e 15%, respectivamente, controle com 10 subconjuntos sem repetições, número de árvores igual a 900, determinação do melhor *mtry* com 4 variáveis avaliadas por nó.

Um coeficiente de determinação de 86,94% e um RMSE de 7,4217 MPa para os dados de teste, demonstrando que o modelo aprendeu o conjunto de dados à que foi treinado, possibilitando assim a utilização do modelo calibrado para outro conjunto de dados.

6.1 Sugestões de trabalhos futuros

Como sugestões para trabalhos futuros tem-se:

- Avaliação do banco de dados para os algoritmos de AM tipo RNA (rede neural artificial) e AdaBoost a fim de verificar o desempenho dos mesmos;
- Verificar a aplicabilidade do modelo para predição de resistência à tração na flexão;
- Realizar a dosagem experimental de traços de argamassa implementando no código os consumos consumo dos insumos e dias de cura desejado a fim de predizer a resistência do traço inserido pelo operador e posteriormente realizar a mistura e ensaio de resistência à compressão;
- Ampliar o conjunto com dados referentes a outros tipos de substituição de insumos em argamassa e realizar a verificação do modelo.

REFERÊNCIAS

- AADI, A. S.; MOHAMMED, A.; ALI, R. A. A.; SALMAN, M. M.: The mechanical properties of green mortar contained aluminum wastes as substitutin of sand. *Materials Today Proceedings*. v. 45, p. 3002 – 3009m 2021.
- ABADOU, Y.; GHRIEB, A.; BUSTAMANTE, R.: Crushed concrete waste influence on dune sand mortar performance. *Materials Today Proceedings*. v. 33, p. 1758 – 1761, 2020.
- AGRAWAL, Y.; SIDDIQUE, S.; SHARMA, R. K.; GUPTA, T.: Valorization of granite production dust in development of rich and lean cement mortar. *J Mater Cycles Waste Manag*. v. 23, p. 686 – 698, 2021.
- ALQURAISHI, M.: ProteinNet: a standardized data set for Machine learning of protein structure. *BMC Bioinformatics*, v. 20, p. 311 – 321, 2019.
- ALVARENGA JÚNIOR., W. J.: *MÉTODOS DE OTIMIZAÇÃO HIPERPARAMÉTRICA: UM ESTUDO COMPARATIVO UTILIZANDO ÁRVORES DE DECISÃO E FLORESTAS ALEATÓRIAS NA CLASSIFICAÇÃO BINÁRIA*. Belo Horizonte, 2018. 65p. Dissertação (Mestrado) - Universidade Federal De Minas Gerais - PPGEE.
- AMBROZEWICZ, P.H.L.: *Materiais de Construção*. São Paulo: PINI, 2012. 457 p.
- AMIN, S. K.; ALLAM, M. E.; GARAS, G. L.; EZZ, H.: A study of the chemical effect of marble and gravite slurry on green mortar compressive strength. *Bull Natl Res Cent*, v. 44, p. 19 – 23. 2020.
- APOLINÁRIO, E. C. A.: *INFLUÊNCIA DA ADIÇÃO DO RESÍDUO PROVENIETNE DO CORTE DE MÁRMORE E GRANITO (RCMG) NAS PROPRIEDADES DE ARGAMASSAS DE CIMENTO PORTLAND*. Salvador, 2014. 193p. Dissertação (Mestrado) – Universidade Federal da Bahia - PPGEAU.
- ARAÚJO, N. N.: *DESEMPENHO DE ARGAMASSAS DE REVESTIMENTO PRODUZIDAS COM AGREGADOS RECICLADOS ORIUNDOS DO RESPIDUO DE CONSTRUÇÃO E DEMOLIÇÃO DA GRANDE NATAL - RN*. Natal, 2014. 129p. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Norte. Centro de Tecnologia - PPGEC.
- ARCHER, K.; KIMES, R. V.: Emprirical characterization of random forest variable importance measures. *Computational Statistics & Data Analysis*, v. 52, n 4, p. 2249 – 2260. 2008.
- ARMAGHANI, D. J.; ASTERIS, P. G.: A comparative study of ANN and ANFIS models for the prediction of cement-based mortar materials compressive strength. *Neural Computing and Applications*, v. 33, p. 4501 – 4532. 2021.
- ASSOCIAÇÃO BRASILEIRA DAS EMPRESAS DE LIMPEZA PÚBLICA E RESÍDUOS ESPECIAIS (ABRELPE). *Panorama dos Resíduos Sólidos no Brasil 2018/ 2019*. ABRELPE, 2019. 68 p. Disponível em: <<http://abrelpe.org.br/panorama/>> Acesso em 15. Jun. 2020.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). NBR 6453: Cal virgem para construção - requisitos. Rio de Janeiro, 2003.

_____. NBR 7175: Cal hidratada para argamassas - requisitos. Rio de Janeiro, 2003.

_____. NBR 7200: Execução de revestimento de paredes e tetos de argamassas inorgânicas - procedimentos. Rio de Janeiro, 1998.

_____. NBR 7215: Cimento portland - determinação da resistência à compressão. Rio de Janeiro, 1996.

_____. NBR 8490: Argamassa endurecidas para alvenaria estrutural - retração por secagem. Rio de Janeiro, 1984.

_____. NBR 9575: Impermeabilização - Seleção e Projeto. Rio de Janeiro, 2003.

_____. NBR 9831: Cimento Portland para poços petrolíferos – Requisitos e métodos de ensaio. Rio de Janeiro, 2020.

_____. NBR 11172: Aglomerantes de origem mineral. Rio de Janeiro, 1990.

_____. NBR 13277: Argamassa para assentamento e revestimento de paredes e tetos - determinação da retenção de água. Rio de Janeiro, 2005.

_____. NBR 13278: Argamassa para assentamento e revestimento de paredes e tetos - determinação da densidade de massa e do teor de ar incorporado. Rio de Janeiro, 2005.

_____. NBR 13279: Argamassa para assentamento e revestimento de paredes e tetos - determinação da resistência à tração na flexão e à compressão. Rio de Janeiro, 2005.

_____. NBR 13281: Argamassa para assentamento e revestimento de paredes e tetos – requisitos. Rio de Janeiro, 2005.

_____. NBR 13528: Revestimento de paredes e tetos de argamassas inorgânicas – determinação da resistência de aderência à tração. Rio de Janeiro, 2019.

_____. NBR 13529: Revestimento de paredes e tetos de argamassas inorgânicas. Rio de Janeiro, 2013.

_____. NBR 15258: Argamassa para revestimento de paredes e tetos - determinação da resistência potencial de aderência à tração. Rio de Janeiro, 2005.

_____. NBR 16697: Cimento Portland - Requisitos. Rio de Janeiro, 2018.

ASTERIS, P. G.; KOOPALIPOOR, M.; ARMAGHANI, D. J.; KOTSONIS, E. A.; LOURENÇO, P. B.: Prediction of cement-based mortars compressive strength using machine learning techniques. *Neural Computing and Applications*, 2021.

AZEVEDO, A. R. G.; CECCHIN, D.; CARMO, D. F.; SILVA, F. C.; CAMPOS, C. M. O.; SHTRUCKA, T. G.; MARVILA, M. T.; MONTEIRO, S. N.: Analysis of the compactness and properties of the hardened state of mortars with recycling of construction and demolition waste (CDW). *Journal of Materials Research and Technology*, v. 9, n. 3, p. 5942 – 5952, 2020.

BACARJI, E., RAMIREZ PERES, W., HAMER, L., LIMA, M. A., MARTINS, M. V., CAMPOS NETO, T. F.: Análise do efeito de adição de diferentes teores de pó de granito nas propriedades mecânicas do microconcreto. *RENEFARA - Revista Eletrônica de Educação da Faculdade Araguaia*, Goiânia, v.4, n.4, p. 11 –24, 2013.

BAUER, L.A.F.: *Materiais de Construção I*. 5ª ed. [reimp.]. Rio de Janeiro: LTC, 2008. 488 p.

BRASIL, Resolução CONAMA nº307, de 05 de julho de 2002. Estabelece diretrizes, critérios e procedimentos para a gestão dos resíduos da construção civil. Publicado no D.O.U. de 17 julho 2002.

_____, Resolução CONAMA nº348, de 16 de agosto de 2004. Altera a Resolução no 307/02 (altera o inciso IV do art. 3º). Publicado no D.O.U. de 17 agosto 2004.

_____, Resolução CONAMA nº431, de 24 de maio de 2011. Altera a Resolução no 307/02 (altera o art. 3º). Publicado no D.O.U. de 25 maio 2011.

_____, Resolução CONAMA nº448, de 12 de janeiro de 2012. Altera a Resolução no 307/02 (altera os art. 2º, 4º, 5º, 6º, 8º, 9º, 10º e 11º e revoga os art. 7º, 12º e 13º). Publicado no D.O.U. de 12 janeiro 2012.

_____, Resolução CONAMA nº469, de 29 de julho de 2015. Altera a Resolução no 307/02 (altera o inciso II do art. 3o. Publicado no D.O.U. de 29 JULHO 2015.

BREIMAN, L.: Bagging Predictors. *Machine Learning*, v.24, p. 123 – 140, 1996.

_____, Random Forests. *Machine Learning*, v.45, p. 5 – 32, 2001.

BU, J.; TIAN, Z.; ZHENG, S.; TANG, Z.: Effect of Sand Content on Strength and Pore Structure of Cement Mortar. *Jornal of Wuhan University of Technology-Mater. Sci. Ed.*, Wuhan, v. 32, n. 2, p. 382 – 390, 2017.

CALLEGARI-JACQUES, S. M.: *Bioestatística: princípios e aplicações*. Porto Alegre: Artemed, 2003. 255p.

CARASEK, H.: Argamassas. In: ISAIA, G. C (Org.). *Materiais de construção civil e princípio de ciência e engenharia de materiais*. 2ª ed. São Paulo, IBRACON, 2010. v. 1 p. 893-943.

CARASEK, H.; ARAÚJO, R. C.; CASCUDO, O.; ANGELIM, R.: Parâmetros da areia que influenciam a consistência e a densidade de massa das argamassas de revestimento. *Revista Matéria*, Rio de Janeiro, v.21, n.3, p. 714 –732, 2016.

CARASEK, H.; GIRARDI, A. C. C.; ARAÚJO, R. C.; ANGELIM, R.; CASCUDO, O.: Estudo e avaliação de agregados reciclados de resíduo de construção e demolição para argamassas de assentamento e de revestimento. *Cerâmica*, São Paulo, v.64, n.370, p. 288 –300, 2018.

CARVALHO, I. M.; BONFIM, W. B.; PAULA, H. M.: USO DE LAMA RESIDUAL DE CONCRETO COMO SUBSTITUTO DA CAL HIDRATADA PARA PRODUÇÃO DE ARGAMASSAS DE REVESTIMENTO. *REEC – Revista Eletrônica de Engenharia Civi.*, Goiânia, v.15, n.2, p. 75 –87, jul/ dez, 2019.

- CASTRO, L. N.; FERRARI, D. G.: *Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações*. 1ª ed. São Paulo: Saraiva, 2016. 682 p.
- CHAHOUR, K.; SAFI, B.: Mechanical behavior and chemical durability of marble-based mortar: Application to panels subjected to punching. *Construction and Building Materials*, v. 232, p. 1 – 10. 2020.
- CHEAH, C. B.; RAMLI, M.: Mechanical strength, durability and drying shrinkage of structural mortar containing HCWA as partial replacement of cement. *Construction and Building Materials*, v. 30, p. 320 – 329. 2012.
- CHEBOUB, T.; SENHADJI, Y.; KHELAFI, H.; ESCADEILLAS, G.: Investigation of the engineering properties of environmentally friendly self-compacting lightweight mortar containing olive kernel shells as aggregate. *Journal of Cleaner Production*, v. 249, 2020.
- CHOUHAN, H. S.; CHOUHAN, R. S.; KALL, P.; NAGAR, R.; GAUTAM, P. K.: Effect of Kota stone slurry on strength properties of cement mortar mixes. *Materials Today: Proceedings*, 2020.
- CRISTIANINI, N.; SHAW-TAYLOR, J.: *Na Introduction to Support Vector Machines and other kernel-based learning methods*. Cambridge: Cambridge University Press, 2000.
- CZARNECKI, S.; SHARIQ, M.; NIKOO, M.; SADOWSKI, Ł.: An inteligente model for the prediction of the compressive strength of cementitious composites with ground granulates blast furnace slag based on ultrasonic pulse velocity measurements. *Measurement*, v. 172, 2021.
- DEMIR, I.; GÜZELKÜCÜK, S.; SEVİM, O.: Effects of sulfate on cement mortar with hybrid pozzolan substitution. *Engineering Science and Technology, na International Journal*, v. 21, p. 275- 283. 2018.
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. P. L. F.: *Inteligência Artificial: Uma Abordagem de Máquina*. Rio de Janeiro: LTC, 2011.
- FÁVERO, L. P.; BELFIORE: *Manual de Análise de Dados*. Rio de Janeiro: Elsevier, 2017.
- FERRARI, J. R.: *REAPROVEITAMENTO DE RESÍDUO DE PLACAS DE CIRCUITO IMPRESSO NA PRODUÇÃO DE ARGAMASSAS*. Vitória, 2018. 75p. Dissertação (Mestrado) – Instituto Federal do Espírito Santo - PPGTS.
- FERREIRA, R. L. S.; ANJOS, M. A. S.; MAIA, C.; PINTO, L.; AZEVEDO, A. R. G.; BRITO, J.: Long-term analysis of the physical properties of the mixed recycled aggregate and their effect on the properties of mortars. *Construction and Building Materials*, v. 274, 2021.
- FORMIGONI, M.; PAVEI, E. G.: *ANÁLISE DA INFLUÊNCIA DA SUBSTITUIÇÃO PARCIAL DO CIMENTO PORTLAND POR RESÍDUOS DE PLACAS CERÂMICAS DESCONFIRMES NA ARGAMASSA*. Criciúma, 2016. 23p. Artigo (Graduação) – Universidade do Extremo Sul Catarinense.
- FIORITO, A. J. S. I.: *Manual de argamassa e revestimento: estudos e procedimentos de execução*. 2ª ed. - São Paulo: Pini, 2009. 231 p.

GHAFOR, K.; QADIR, S.; MAHMOOD, W.; MOHAMMED, A.: Statistical variations and new correlation models to predict the mechanical behaviour of the cement mortar modified with silica fume. *Geomechanics and Geoengineering - A International Journal*, 2020.

GOMES, A. O.; NEVES, C. M. M.: Proposta de método de dosagem racional de argamassas contendo argilominerais. *revista Ambiente Construído*, Porto Alegre, v.2, n.2, p. 19 –30, 2002.

GUERRA, T. D.; LIRA, M. O.; PORTO, T. R.; LUZ, M. S. G.; MENDONÇA, A. M. G. D.: ARGAMASSAS MANUFATURADAS COM SUBSTITUIÇÃO PARCIAL DO CIMENTO POR PET TRITURADO. In: *CONGRESSO NACIONAL DE PESQUISA E ENSINO DE CIÊNCIAS - CONAPESC*, III, 2018, Campina Grande. Anais, Campina Grande: editora realiza, 2018, p. 1 – 9.

HERBRICH, R.: *Learning Kernel Classifiers: Theory and Algorithms*. Cambridge, MIT Press, 2001.

HSU, C.W.; LIN, C.J.: Uma comparação de métodos para vetor de suporte multiclasse máquinas. *Transações IEEE em Neural Networks*, v.13, n. 2, p. 415–425, 2002.

HUANG, Q.; ZHU, X.; XIONG, G.; WANG, C.; LIU, D.; ZHAO, L.: Recycling of crushed waste clay brick as aggregates in cement mortars: An approach from macro- and micro-scale investigation. *Construction and Building Materials*, v. 274, 2021.

ISHWARAN, H.; O'BRIEN, R.: REPLY: THE STANDARDIZATION AND AUTOMATION OF MACHINE LEARNING FOR BIOMEDICAL DATA. *The Journal of Thoracic and Cardiovascular Surgery*. 2 p., 2020.

JAYALAKSHIM, T.; SANTHAKUMARAN, A.: Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*. v.3, n. 1, p. 89 - 93, 2011.

JO, J.-M.: Effectiveness of Normalization Pre-Processing of Big Data to the Machine Learning Performance. *Journal of the KIECS*. v.14, n. 3, p. 547 -552, 2019.

JUSTO-REINOSO, I.; SRUBAR III, W. V.; CAICEDO-RAMIREZ, A.; HERNANDEZ, M. T.: Fine aggregate substitution by granular activated carbon can improve physical and mechanical properties of cement mortars. *Construction and Building Materials*, v. 164, p. 750 – 759, 2018.

KABAY, N.; MIYAN, N.; ÖZKAN, H.: Utilization of pumice powder and glass microspheres in cement mortar using paste replacement methodology. *Construction and Building Materials*, v. 282, 2021.

KABEER, K. I. S. A.; VYAS, A. K.: Experimental investigation on utilization of dried marble slurry as fine aggregate in lean masonry mortars. *Journal of Building Engineering*, v. 23, p. 185 – 192, 2019.

KUHN, M.: *The caret Package*. 2019. Disponível em: <<https://topepo.github.io/caret/index.html>>. Acesso em 03. 08. 2021.

KURZ, M. N.; BRANDELLI, T. M.; PALIGA, C. M.; TORRES, A. S.: A potencialidade do uso de resíduo de borracha de pneu em argamassa: análise das propriedades físicas e mecânicas. *Revista Matéria*, Rio de Janeiro, v. 23, n. 3, 15 p., 2018.

LARA, G. T. D.; SALVADOR, C. M.; GARCIA, R. S.: ANÁLISE COMPARATIVA DE RESISTÊNCIA À COMPRESSÃO ENTRE ARGAMASSAS DE REVESTIMENTO À BASE DE CAL HIDRATADA E ADITIVO PLASTIFICANTE LÍQUIDO. *Revista Funec Científica - Multidisciplinar*, Santa Fé do Sul, v.6, n8, p. 180 –197, 2017.

LEE, T. C.; RAO, M. K.: Recycling municipal incinerator fly- and scrubber-ash into fused slag for the substantial replacement of cement in cement-mortars. *Waste Management*, v. 29, p. 1952 – 1959. 2009.

LI, L. G.; ZHUO, Z. Y.; ZHU, J.; KWAN, A. K. H.: Adding ceramic polishing waste as paste substitute to improve sulfate and shrinkage resistances of mortar. *Poder Technology*, v. 362. P. 149 – 156. 2020.

LI, L. G.; LIN, Z. H.; CHEN, G. M.; KWAN, A. K. H.: Reutilizing clay brick dust as paste substitution to produce environment-friendly durable mortar. *Journal of Cleaner Production*, v. 274. 2020.

LIMA, R., G., R.: *DESENVOLVIMENTO DE UM MODELO DE PREVISÃO HIDROLÓGICO USANDO MÁQUINA VETORIAL DE SUPORTE REGRESSIVO: Uma Aproximação Computacional para Modelagem da Bacia do rio Arkansas*. Mossoró, 2018. 100p. Dissertação (Mestrado) - Universidade Federal Rural do Semiárido – Universidade Do Estado do Rio Grande do Norte.

LIMA, A. H. N.; LACERDA, W. S.; SCALCO NETO, H.: Seleção de características de dados utilizando Redes Neurais Artificiais. In: *Brasilian Symposium on Information Systems, XIII*, 2017, Lavras. Anais SBSI: 2017, p. 135 – 142.

LIRA, S. A.: *ANÁLISE DE CORRELAÇÃO: ABORDAGEM TEÓRICA E DE CONSTRUÇÃO DOS COEFICIENTES COM APLICAÇÕES*. Curitiba, 2004. 196p. Dissertação (Mestrado) - Universidade Federal do Paraná. PPG em Métodos Numéricos em Engenharia dos Setores de Ciências Exatas e de Tecnologia.

LLAJARUNA, M. A. V.: *Estudo do solo-cimento auto adensável para a fabricação de tijolos de pó de mármore e resíduo de construção*. Ilha Solteira, 2016. 71p. Dissertação (Mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira.

LORENA, A. C.; CARVALHO, A. P. L. F.: Uma introdução às *Support Vector Machines*. *Revista de Informática Teórica e Aplicada*, São Paulo, v.14, n2, p. 43 – 67, 2007.

LUGER, G.: *Artificial Intelligence – Structures and Strategies for Complex Problem Solving*. – 5th ed., ADDISON-WESLEY - England, 2005. 903 p.

MAHMUD, H. M.; AZNIETA, A. A. F. N.; GATEA, S. J.: Evaluation of Rubberized Fibre Mortar Exposed to Elevated Temperature using Destructive and Non-Destructive Testing. *Journal of Civil Engineering*, v. 21, n. 4, p. 1347 - 1358, 2017.

MARANGU, J. M.: Prediction of Compressive Strength of Calcined Clay Based Cement Mortars Using Support Vector Machine and Artificial Neural Network Techniques. *Journal of Sustainable Construction Materials and Technologies*, v. 5, n. 1, p. 392 - 398, 2020.

MARANI, A.; NEHDI, M. L.: Machine learning prediction of compressive strength for phase change materials integrated cementitious composites. *Construction and Building Materials*, v. 265, 2020.

MARVILA, M. T.; AZEVEDO, A. R. G.; ZANELATO, E. B., ALEXANDRE, J.; XAVIER, G. C.; ESPIRITO SANTO, T. L.; CERQUEIRA, N. A.; BRUZZI, G.; PIROVANE, T.: Interferência da relação água/cimento nas propriedades tecnológicas de argamassas no estado endurecido. In: *Congresso Brasileiro de Cerâmica*, LXIII, 2019, Bonito. Anais Bonito: 2019, p. 579 – 588.

MAZURANA, L.; POSSAN, E.; BITTENCOURT, P. R. S.: *CARBONATATION AND CO2 UPTAKE IN RENDERING MORTARS PRODUCED WITH RECYCLED CONSTRUCTION AND DEMOLITION WAST*. In: Congreso Latinoamericano de Patología e Construcción, XV y Congreso de Control de Calidad em la Construcción, XVII, 2019, Tuxtla Gutiérrez. Anais Tuxtla Gutiérrez: 2019, 11 p.

MITCHELL, T. M.: *Machine Learning*. NY , McGraw-Hill, 1997. 432 p.

MOHAMMADHOSSEINI, H.; LIM, N. H. A. S.; TAHIR, M. MD.; ALYOUSEF, R.; SAMADI, M.: Performance evaluation of green mortar comprising ceramic wasteas cement and fine aggregates replacement. *SN Applied Sciences*, v. 1. p. 557 – 563. 2019.

MOHAMMED, A.; RAFIQ, S.; SIHAG, P.; KURDA, R.; MAHMOOD, W.; GHAFOR, K.; SARWAR, W.: ANN, M5P-tree and nonlinear regression approaches with statistical evaluatins to predict the compressive strength of cement-based mortar modified with flay ash. *Journal of Materials Research and Technology*, n. 9, v. 6. p. 12416 – 12427. 2020.

MONTAÑO, R. A. N. R.: *Aplicação de Técnicas de Aprendizado de Máquina na Mensuração Florestal*. Curitiba, 2016. 102p. Tese (Doutorado) - Universidade Federal do Paraná. Setor de Ciências Exatas, PPGI.

MORICONI, G.; CORINALDESI, V.; ANTONUCCI, R.: Environmentally-friendly mortars: a way to improve bond between mortar and brick. *Materials and Structures/ Matériaux et Constructions*, v. 36, p. 702 – 708. 2003.

MOURA, A. A.: *ARGAMASSA COM SUBSTITUIÇÃO PARCIAL DO CIMENTO POR RESÍDUOS INDUSTRIAIS*. Londrina, 2018. 107p. Tese (Doutorado) - Universidade Tecnológica Federal do Paraná. PPGEA.

MOURA, W. A.; GONÇALVES, J. P.; LEITE, R. S.: Utilização do Resíduo de corte de mármore e granito em argamassas de revestimento e confecção de lajotas para piso. *Sitentibus*, Feira de Santana, v.26, p. 49 –61, 2002.

NASR, M. S.; ALI, I. M.; HUSSEIN, A. M.; SHUBBAR, A. A., KAREEM, Q. T., ABDULAMERR, A., T.: Utilization of locally produced waste in the production of sustainable mortar. *Case Studies in Construction Materials*, v. 13, 2020.

NAZARI, A.; SANJAYAN, J. G.: Modelling of compressive strength of geopolymer paste, mortar and concrete by optimized Support vector machine. *Ceramics International*, v. 41, p. 12164 - 12177, 2015.

NEGREIROS, K. S.; SENNA, A. O.; MENEZES, J.; ARAKI, S.: APLICAÇÃO DE MACHINE LEARNING NA PREDIÇÃO DA RESISTENCIA DO CIMENTO. *REGRAD – Revista Eletrônica de Graduação do UNIVEM*, v. 13, n. 3, p. 1 - 15, 2020.

NING, B.; XU, J.; CHEN, S.: Mechanical Properties and Solidified Mechanism of Tailings Mortar with Waste Glass. *Journal of Wuhan University o Technology - Mater. Sci. Ed.*, v. 36, n. 6, p. 1240 – 1246. 2015.

ONYARI, E. K.; IKOTUN, B. D.: Prediction of compressive and flexural strengths of a modified zeolite additive mortar using artificial neural network. *Construction and Building Materials*, v. 187, p. 1232-1241, 2018.

OZCAN, G.; KOCAK, Y.; GULBANDILAR, E.: Estimation of compressive strength of BFS and WTRP blended cement mortars with machine learning models. *Computers and Concrete*, v. 9, N. 3, p. 275-282, 2017.

PATEL, D.; SHIVASTAVA, R.; TIWARI, R. P.; YADAV, R. K.: Properties of cement mortar in substitution with waste fine glass powder and environmental impact study. *Journal of Buiding Engineering*. v. 27,2020.

PETRY, N. S.; DELONGUI, L.; MULLER, A. L.; MASUERO, A. B.; DAL MOLIN, D. C. C.: Avaliação do uso de resíduos de marmoraria na produção de concretos. *Revista de arquitetura IMED*, Passo Fundo, v.6, n.2, p. 1 –14, 2017.

PCZIECZEK, A.; EFFTING, C.; GOMES, I. R.; SCHACKOW, A., HENNING, E.: Análise estatística de propriedades mecânicas de argamassas com cinza volante e resíduo de borracha de pneus. *revista IBRACON de estruturas e materiais*, São Paulo, v.12, n.4, 2019.

PIMENTEL, L.; PISSOLATO Jr., O.; JACINTHO, A. E. P. G. A; MARTINS, H. L. S.: Argamassa com areia proveniente da britagem de resíduo de construção civil - Avaliação de características físicas e mecânicas. *Revista Matéria*, Rio de Janeiro, v.23, n.1, 2018.

PINI: *Tabelas de Composições de Preços e Orçamentos – TCPO - 15ª ed.* –São Paulo - PINI, 2017. 1028 p.

POLAD, R.; DEO, S. V.; RAMTEKKAR, G. D.: Utilization of waste from steel and iron industry as replacement of cement in mortars. *J Mater Cycles Waste Manag.* v. 21, p. 1361 – 1375, 2019.

R Development Core Team. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. 2009. Disponível em: <<http://www.R-project.org>> Acesso em 15. Mai. 2021.

RAINI, I.; JABRANE, R.; MESRAR, L.; AKDIM, M.: Evaluatin of mortar properties by combining concrete and brick wastes as fine aggregate. *Case Studies in Construction Materias*. v. 13, 2020,

RAMJAN, S.; TANGCHIRAPAT, W.; JATURAPITAKKUL, C.: Effects of Binary and Ternary Blended Cements Made from Palm Oil Fuel Ash and Rice Husk Ash on Alkali-Silica Reaction of Mortar. *Arab J Sci Eng.* v. 43, p. 1941 – 1954, 2018.

RECENA, F. A. P.: *Conhecendo Argamassa.* - 2ª ed. - Porto Alegre - EDIPUCRS, 2012. 188 p.

RIBEIRO, K. B.: *INFLUÊNCIA DA SUBSTITUIÇÃO DE CIMENTO POR PENTÓXIDO DE NIÓBIO NA RESISTÊNCIA À COMPRESSÃO DE ARGAMASSAS.* Brasília, 2019. 11 p., Relatório de Iniciação Científica (IC), UniCEUB.

ROCHA, S. O. N.; MAIA, N. A.; CARVALHO JÚNIOR, A. B.; DIAS, M. P. A.: Utilização de redes neurais para estimativa da resistência à compressão do concreto simples. *Brasilian Journal of Development*, v. 6, n. 10, p. 79910 – 79922, 2020.

RUSSEL, S.; NORVIG, P.: *Inteligência Artificial.* 3ª ed., Rio de Janeiro, Elsevier, 2013.

SABBATINI, F. H.: *Argamassas de assentamento para paredes de alvenaria resistente.* São Paulo, ABCP, 2ª ed. 1998. 44 p.

SAFI, B.; SAIDI, M.; DAOUI, A.; BELLAL, A.; MECHEKAK, A.; TOUMI, K.: The use of seashells as a fine aggregate (by sand substitution) in self - compacting mortar (SCM). *Construction and Building Materials*, v. 78, 2015.

SALIH, A.; RAFIQ, S.; SIHAG, P.; GHAFOR, K.; MAHMOOD, W.; SARWAR, W.: Systematic multiscale models to predict the effect of high – volume fly ash on the maximum compression stress of cement – based mortar at various water/ cement ratios and curing times. *Measurement*, v. 171, 2021.

SANTANA, F. B.: *FLORESTA ALEATÓRIA PARA DESENVOLVIMENTO DE MODELOS MULTIVARIADOS DE CLASSIFICAÇÃO E REGRESSÃO EM QUÍMICA ANALÍTICA.* Campinas, 2016. 139p. Tese (Doutorado) – Universidade Estadual de Campinas.

SANTOS, D. V.; CABRAL, A. E. B.: Análise técnica da reciclagem de resíduos de construção em canteiro de obras. *Ambiente Construído*, Porto Alegre, v. 20, n. 3, p. 363-383, jul./set. 2020.

SANTOS, R. A.; LIRA, B. B.; RIBEIRO, A. C. M.: ARGAMASSA COM SUBSTITUIÇÃO DE AGREGADO NATURAL POR RESÍDUO DE BRITAGEM DE GRANITO. *Rev. Elet. em Gestão, Educação e Tecnologia Ambiental*, Santa Maria, v. 8, n. 8, p. 1818 - 1828, set./dez. 2012.

SANTOS, M. F. N.; BATTISTELLE, R. A.; HORI, C. Y.; JULIOTI, P. S.: Importância da avaliação do ciclo de vida na análise de produtos: possíveis aplicações na construção civil. *GEPROS. Gestão da Produção, Operações e Sistemas*, Bauru, v. 16, n. 2, p. 57 - 73. 2011.

SELVARANJAN, K.; NAVARATNAM, S.; GAMAGE, J. C. P. H.; THAMBOO, J.; SIDDIQUE, R.; ZHANG, J.; ZHANG, G.: Thermal and environmental impact analysis of rice husk ash-based mortar as insulating wall plaster. *Construction and Building Materials*, v. 283, 2021.

SEVIM, U. K.; BILGIC, H. H.; CANSIZ, O. F.; OZTURK, M.; ATIS, C. D: Compressive strength prediction models for cementitious composites with fly ash using machine learning techniques. *Construction and Building Materials*, v. 271, 2021.

SHALEV-SHWARTZ, S; BEM-DAVID, S.: *Understanding Machine Learning From Theory to Algorithms*. New York – Cambridge University Press, 2014. 397 p.

SILVA, A. R.; CABRAL, C.; PINTO, E. N. M. G.: SUBSTITUIÇÃO PARCIAL DO CIMENTO PORTLAND POR RESÍDUO DE CERÂMICA VERMELHA EM ARGAMASSAS: ESTUDO DA ATIVIDADE POZOLÂNICA. In: *Congresso Brasileiro de Engenharia e Ciência dos Materiais – CBECiMat. XXII*, 2016, Natal. Anais, Natal: 2016. p. 1144 - 1154.

SILVA, I. A. C.: *ADIÇÃO DE FIBRAS DE PAPEL KRAFT E GESSO RECICLADO EM ARGAMASSAS DE ASSENTAMENTO*. Catalão, 2019. 92p. Trabalho de Conclusão de Curso (Graduação) – Universidade Federal de Goiás – Regional Catalão.

SILVA NETO, A. P. A.; BRITES, B. G.; SANTOS, L. L.: *SUBSTITUIÇÃO DO AGREGADO MIÚDO POR RESÍDUO PROVENIENTE DO BENEFICIAMENTO DO MÁRMORE E GRANITO (RBMG) EM ARGAMASSA*. Campo Grande, 2016. 69p. Trabalho de Conclusão de Curso (Graduação) – Uniderp.

SINGH, L. P.; GOEL, A.; BHATTACHARYYA, S. K.; AHALAWAT, S.; SHARMA, U.; MISHRA, G.: Effect of Morphology and Dispersibility of Silica Nanoparticles on the Mechanical Behaviour of Cement Mortar. *International J of Concrete Structures and Materials*, v. 9, n. 2, p. 207 - 217, 2015.

SINGH, D.; SINGH, B.: Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, v. 97, parte B, 2020.

SJÖSTRÖM, C. *Service life of the building*. In: Applications of the performance concept in building. Proceedings. CIB: Tel Aviv, V. 2, p. 6-1:6-11, 1996.

SLAPNIK, M.; ISTENIČ, D.; PITAR, M.; UDOVČ, A.: Extending life cycle assessment normalization factors and use of machine learning – A Slovenian case study. *Ecological Indicators*, v. 50, p. 161 - 172, 2015.

SMOLA, A. J.; SCHÖLKOPF, B.: A tutorial on Support vector regression*. *Statistics and Computing*, v. 14, p. 199-220, 2004. Disponível em <<https://alex.smola.org/papers/2004/SmoSch04.pdf>> Acesso em 09.05.2021.

SUN, Y.; LI, G.; ZHANG, J.; QIAN, D.: Prediction of the Strength of Rubberized Concrete by an Evolved Random Forest Model. *Hindawi*, 2019.

SVETNIK, V.; LIAW, A.; TONG, C.; CULBERSON, C.; SHERIDAN, R. P.; FEUSTON, B. P.: Random Forest: A Classification and Regression Tool for Compound Classification and QSAR Modeling. *J. Chem. Inf. Comput. Sci*, 2003, n. 43, p. 1947 - 1958.

TOKARSKI, R. B.: *COMPORTAMENTO DA AREIA DE BRITAGEM DE ROCHA CALCÁRIA NA ARGAMASSA DE REVESTIMENTO*. Curitiba, 2017. 81p. Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná -PPGE.

TRENTIN, P. O.; MANICA, J.; VANZETTO, S. C.; MARANGONI, B.; ZALESKI, A.: Substituição parcial de agregado miúdo por resíduo de vidro moído na produção de argamassa. *Revista Matéria*, v. 25, n. 1, 2020,

VAPNIK, V. N., B.: *The Nature of Statistical Learning Theory*. Springer – Verlag, New York, 1995.

YARNOLD, P. R.; LINDEN, A.: Using Machine Learning to Model Dose-Response Relationships via ODA: Eliminating Response Variable Baseline Variation by Ipsative Standardization. *Optimal Data Analysis*, v. 5, p. 41 – 52, 2016.

YUN, C. M.; RAHMAN, MD. R.; PHING, C. Y. W.; CHIE, A. W. M.; BAKRI, M. K. B.: The curing times effect on the strength of ground granulated blast furnace slag (GGBFS) mortar. *Construction and Building Materials*, v. 260, 2020.

ZHANG, J.; HUANG, Y.; MA, G.; NENER, B.: Mixture optimization for environmental, economical and mechanical objectives in silica fume concrete: A novel frame-work based on machine learning and a new meta-heuristic algorithm. *Resources, Conservation & Recycling*, v. 167, p. 1 - 21, 2021.

ZHAO, Z.; BENZERZOUR, M.; ABRIAK, N.; DAMIDOT, D.; COURARD, L.; WANG, D.: Use of uncontaminated marine sediments in mortar and concrete by partial substitution of cement. *Cement and Concrete Composites*, v. 93, p. 155 – 162, 2018.

APÊNDICE A

BANCO DE DADOS – RESISTÊNCIA À COMPRESSÃO ARGAMASSAS

Tabela A – Banco de dados argamassa (continua).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
1	Silva Neto <i>et al.</i> (2016)	384,30	531,00	2350,00	0,00	0,00	0,00	648,00	28,00	3,50
		384,30	531,00	2230,00	0,00	117,45	0,00	648,00	28,00	5,00
		384,30	531,00	2110,00	0,00	234,40	0,00	648,00	28,00	6,20
		384,30	531,00	2000,00	0,00	352,30	0,00	648,00	28,00	5,60
		384,30	531,00	2350,00	0,00	0,00	0,00	648,00	7,00	2,50
		384,30	531,00	2230,00	0,00	117,45	0,00	648,00	7,00	3,00
		384,30	531,00	2110,00	0,00	234,40	0,00	648,00	7,00	2,70
		384,30	531,00	2130,00	0,00	217,83	0,00	648,00	1,00	2,63
2	Silva (2019)	286,28	0,00	1431,40	0,00	0,00	0,00	357,85	28,00	3,58
3	Lara <i>et al.</i> (2017)	787,45	50,08	905,11	0,00	0,00	0,00	377,13	14,00	20,00
		786,28	50,01	903,76	0,00	0,00	1,51	250,00	14,00	18,40
		181,57	134,20	1589,39	0,00	0,00	0,00	275,51	7,00	1,71
4	Araújo (2014)	181,44	134,11	1270,60	258,75	0,00	0,00	293,67	7,00	1,39
		181,07	133,84	951,02	516,45	0,00	0,00	312,70	7,00	1,29
		182,86	135,16	640,27	782,32	0,00	0,00	323,72	7,00	1,18
		183,70	135,78	321,61	1047,89	0,00	0,00	321,61	7,00	1,25
		185,79	137,32	0,00	1324,78	0,00	0,00	349,05	7,00	1,42
		197,85	0,00	1731,90	0,00	0,00	0,00	271,49	7,00	1,12

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
4	Araújo (2014)	201,71	0,00	1412,57	287,66	0,00	0,15	279,84	7,00	1,14
		205,73	0,00	1080,53	586,78	0,00	0,30	285,42	7,00	1,38
		209,91	0,00	734,99	898,05	0,00	0,46	291,22	7,00	1,57
		214,33	0,00	375,23	1222,60	0,00	0,31	297,35	7,00	1,30
		218,94	0,00	0,00	1561,13	0,00	0,16	303,74	7,00	2,16
		181,57	134,20	1589,38	0,00	0,00	0,00	275,51	28,00	2,13
		181,44	134,11	1270,60	258,75	0,00	0,00	293,67	28,00	1,89
		181,07	133,83	951,01	516,45	0,00	0,00	312,70	28,00	1,75
		182,86	135,16	640,27	782,32	0,00	0,00	323,72	28,00	1,49
		183,70	135,78	321,61	1047,89	0,00	0,00	338,48	28,00	1,38
		185,79	137,32	0,00	1324,78	0,00	0,00	349,05	28,00	1,55
		197,85	0,00	1731,90	0,00	0,00	0,00	274,48	28,00	1,33
		201,71	0,00	1412,57	287,66	0,00	0,15	279,84	28,00	1,25
		205,73	0,00	1080,53	586,78	0,00	0,30	285,42	28,00	1,47
		209,91	0,00	734,99	898,04	0,00	0,46	291,21	28,00	1,65
		5	Tokarski (2017)	214,33	0,00	375,23	1222,60	0,00	0,31	297,35
218,94	0,00			0,00	1561,13	0,00	0,16	303,74	28,00	2,64
404,16	0,00			1423,34	0,00	0,00	0,71	233,63	3,00	5,18
404,16	0,00			1423,34	0,00	0,00	0,71	233,63	7,00	5,17
404,16	0,00			1423,34	0,00	0,00	0,71	233,63	28,00	10,10
684,00	0,00			1538,00	0,00	0,00	0,00	239,00	3,00	34,89
6	Cheah e Ramli. (2012)	684,00	0,00	1538,00	0,00	0,00	0,00	239,00	7,00	38,15
		684,00	0,00	1538,00	0,00	0,00	0,00	239,00	28,00	44,90
		684,00	0,00	1538,00	0,00	0,00	0,00	239,00	90,00	48,25
		684,00	0,00	1538,00	0,00	0,00	0,00	239,00	90,00	48,25

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
7	Lee e Rao (2009)	536,43	0,00	1475,19	0,00	0,00	0,00	260,24	7,00	34,43
		536,43	0,00	1475,19	0,00	0,00	0,00	260,24	28,00	39,04
8	Palod 2019	500,00	0,00	1500,00	0,00	0,00	0,00	200,00	28,00	43,00
		529,08	0,00	1375,62	0,00	0,00	0,00	312,16	3,00	8,00
		529,08	0,00	1375,62	0,00	0,00	0,00	312,16	7,00	12,00
		529,08	0,00	1375,62	0,00	0,00	0,00	312,16	28,00	20,00
		529,08	0,00	1375,62	0,00	0,00	0,00	312,16	63,00	24,00
		529,08	0,00	1375,62	0,00	0,00	0,00	312,16	91,00	24,00
		524,33	0,00	1363,27	0,00	26,22	0,00	309,36	3,00	13,50
		524,33	0,00	1363,27	0,00	26,22	0,00	309,36	7,00	17,00
		524,33	0,00	1363,27	0,00	26,22	0,00	309,36	28,00	22,00
		524,33	0,00	1363,27	0,00	26,22	0,00	309,36	63,00	26,00
		524,33	0,00	1363,27	0,00	26,22	0,00	309,36	91,00	31,00
		9	Apolinário (2014)	519,67	0,00	1351,14	0,00	51,97	0,00	306,60
519,67	0,00			1351,14	0,00	51,97	0,00	306,60	7,00	18,00
519,67	0,00			1351,14	0,00	51,97	0,00	306,60	28,00	20,00
519,67	0,00			1351,14	0,00	51,97	0,00	306,60	63,00	24,00
519,67	0,00			1351,14	0,00	51,97	0,00	306,60	91,00	32,00
515,99	0,00			1341,59	0,00	77,40	0,00	304,44	3,00	12,00
515,99	0,00			1341,59	0,00	77,40	0,00	304,44	7,00	13,00
515,99	0,00			1341,59	0,00	77,40	0,00	304,44	28,00	19,50
515,99	0,00			1341,59	0,00	77,40	0,00	304,44	63,00	23,50
515,99	0,00			1341,59	0,00	77,40	0,00	304,44	91,00	32,00
225,18	139,61			1483,95	0,00	0,00	1,80	304,91	28,00	3,59
224,32	139,08			1478,25	0,00	11,22	1,79	303,74	28,00	3,51
223,46	1338,54			1472,60	0,00	22,35	1,79	302,58	28,00	4,55

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
9	Apolinário (2014)	222,61	138,02	1466,98	0,00	33,39	1,78	301,42	28,00	3,65
10	Silva <i>et al.</i> (2016)	511,61	0,00	1534,82	0,00	0,00	0,00	245,97	7,00	21,55
		511,61	0,00	1534,82	0,00	0,00	0,00	245,97	28,00	25,27
		506,96	0,00	1518,91	0,00	0,00	0,00	262,43	60,00	20,00
11	Moura (2018)	506,96	0,00	1518,91	0,00	0,00	0,00	262,43	1,00	10,30
		506,96	0,00	1518,91	0,00	0,00	0,00	262,43	3,00	16,80
		506,96	0,00	1518,91	0,00	0,00	0,00	262,43	7,00	17,00
		506,96	0,00	1518,91	0,00	0,00	0,00	262,43	28,00	18,60
12	Formigoni e Pavei (2016)	258,44	23,88	1668,59	0,00	0,00	0,00	164,33	28,00	10,67
		251,93	94,48	1914,70	0,00	0,00	0,00	154,79	7,00	3,20
13	Trentin <i>et al.</i> (2020)	251,93	94,48	1914,70	0,00	0,00	0,00	154,79	28,00	4,00
		251,93	94,48	1914,70	0,00	0,00	0,00	154,79	63,00	3,40
		251,93	94,48	1914,70	0,00	0,00	0,00	154,79	91,00	4,20
		151,63	113,72	1625,10	0,00	0,00	0,00	278,22	7,00	0,54
14	Guerra <i>et al.</i> (2018)	151,63	113,72	1625,10	0,00	0,00	0,00	278,22	14,00	0,87
		151,63	113,72	1625,10	0,00	0,00	0,00	278,22	28,00	0,90
		516,23	0,00	1548,68	0,00	0,00	0,00	248,19	1,00	22,00
15	Ribeiro (2019)	516,23	0,00	1548,68	0,00	0,00	0,00	248,19	3,00	29,00
		516,23	0,00	1548,68	0,00	0,00	0,00	248,19	7,00	28,00
		516,23	0,00	1548,68	0,00	0,00	0,00	248,19	28,00	34,00
		261,70	0,00	1596,37	0,00	0,00	0,00	316,66	28,00	7,12
16	Pimentel <i>et al.</i> (2018)	241,50	0,00	1031,21	441,95	0,00	0,00	350,18	28,00	5,86
		216,00	0,00	527,04	790,56	0,00	0,00	403,92	28,00	5,65
		207,50	415,00	1224,25	0,00	0,00	0,00	311,25	28,00	6,36
		206,50	413,00	846,65	351,05	0,00	0,00	330,40	28,00	5,16
		203,90	407,80	489,36	693,26	0,00	0,00	387,41	28,00	3,71

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
17	<i>Pcziecsek et al.</i> (2019)	234,38	161,46	1861,98	0,00	0,00	0,00	477,86	28,00	3,45
		190,00	380,00	1139,90	0,00	0,00	0,00	313,50	28,00	5,60
		190,00	380,00	854,90	285,00	0,00	0,00	342,00	28,00	5,80
		190,00	380,00	570,00	570,00	0,00	0,00	351,50	28,00	6,26
		190,00	380,00	285,00	854,90	0,00	0,00	381,90	28,00	6,26
18	<i>Mazurana et al.</i> (2019)	190,00	380,00	0,00	1139,90	0,00	0,00	412,30	28,00	5,80
		190,00	380,00	1139,90	0,00	0,00	0,00	313,50	63,00	6,01
		190,00	380,00	854,90	285,00	0,00	0,00	342,00	63,00	6,05
		190,00	380,00	570,00	570,00	0,00	0,00	351,50	63,00	7,65
		190,00	380,00	285,00	854,90	0,00	0,00	381,90	63,00	7,50
		190,00	380,00	0,00	1139,90	0,00	0,00	412,30	63,00	6,70
		162,76	162,76	0,00	976,56	0,00	0,00	358,07	7,00	2,58
		162,76	325,52	0,00	2250,00	0,00	0,00	511,07	7,00	0,57
19	<i>Santos et al.</i> (2012)	162,76	162,76	0,00	976,56	0,00	0,00	358,07	28,00	3,99
		162,76	325,52	0,00	2250,00	0,00	0,00	511,07	28,00	0,87
		214,18	64,25	1621,70	0,00	0,00	0,00	284,81	7,00	2,01
20	<i>Carvalho et al.</i> (2019)	214,18	64,25	1621,70	0,00	0,00	0,00	284,81	28,00	2,24
		212,22	212,22	1273,32	0,00	0,00	0,00	282,25	14,00	3,12
		211,46	211,46	1268,76	0,00	0,00	0,00	338,34	14,00	2,50
		208,67	208,67	1252,02	0,00	0,00	0,00	400,65	14,00	2,04
21	<i>Marvila et al.</i> (2019)	138,91	277,88	1250,19	0,00	0,00	0,00	243,09	14,00	2,45
		138,73	277,46	1248,57	0,00	0,00	0,00	305,21	14,00	2,12
		136,49	272,98	1228,41	0,00	0,00	0,00	382,17	14,00	1,56
		375,56	0,00	1126,68	0,00	0,00	0,00	1126,68	14,00	9,12

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
21	Marvila <i>et al.</i> (2019)	365,96	0,00	1097,88	0,00	0,00	0,00	256,17	14,00	8,64
		358,61	0,00	1075,83	0,00	0,00	0,00	315,58	14,00	8,02
		371,11	0,00	1113,33	0,00	0,00	0,00	196,69	14,00	9,27
		380,00	0,00	1140,00	0,00	0,00	0,00	273,60	14,00	8,94
		391,11	0,00	1173,33	0,00	0,00	0,00	340,27	14,00	8,53
		212,22	212,22	1273,32	0,00	0,00	0,00	282,25	28,00	4,67
		211,46	211,46	1268,76	0,00	0,00	0,00	338,34	28,00	4,19
		208,67	208,67	1252,02	0,00	0,00	0,00	400,65	28,00	3,71
		138,91	277,88	1250,19	0,00	0,00	0,00	243,09	28,00	4,22
		138,73	277,46	1248,57	0,00	0,00	0,00	305,21	28,00	3,65
		136,49	272,98	1228,41	0,00	0,00	0,00	382,17	28,00	1,98
		375,56	0,00	1126,68	0,00	0,00	0,00	1126,68	28,00	13,86
		365,96	0,00	1097,88	0,00	0,00	0,00	256,17	28,00	12,43
		358,61	0,00	1075,83	0,00	0,00	0,00	315,58	28,00	11,37
		371,11	0,00	1113,33	0,00	0,00	0,00	196,69	28,00	14,23
380,00	0,00	1140,00	0,00	0,00	0,00	273,60	28,00	13,15		
391,11	0,00	1173,33	0,00	0,00	0,00	340,27	28,00	12,86		
22	Ferrari (2018)	529,60	0,00	1589,00	0,00	0,00	0,00	254,12	28,00	32,00
23	Kurz <i>et al.</i> (2018)	212,00	0,00	773,80	0,00	0,00	0,00	102,92	7,00	15,71
		212,00	0,00	773,80	0,00	0,00	0,00	102,92	28,00	24,70
24	Agrawal <i>et al.</i> (2021)	563,96	0,00	1924,30	0,00	0,00	0,00	310,18	7,00	17,00
		563,96	0,00	1443,22	390,99	0,00	0,00	310,18	7,00	17,50
		563,96	0,00	962,15	781,97	0,00	0,00	310,18	7,00	22,00
		563,96	0,00	481,07	1172,96	0,00	0,00	310,18	7,00	5,20
		563,96	0,00	0,00	1563,94	0,00	0,00	310,18	7,00	4,00
		402,83	0,00	2061,75	0,00	0,00	0,00	310,18	7,00	7,50

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
24	Agrawal <i>et al.</i> (2021)	402,83	0,00	1718,12	279,28	0,00	0,00	310,18	7,00	8,10
		402,83	0,00	1374,50	558,55	0,00	0,00	310,18	7,00	9,20
		402,83	0,00	1030,87	837,83	0,00	0,00	310,18	7,00	11,20
		402,83	0,00	687,25	1117,10	0,00	0,00	310,18	7,00	8,40
		402,83	0,00	343,62	1396,38	0,00	0,00	310,18	7,00	4,90
		402,83	0,00	0,00	1675,65	0,00	0,00	310,18	7,00	3,20
		563,96	0,00	1924,30	0,00	0,00	0,00	310,18	7,00	17,00
		422,97	0,00	1924,30	0,00	97,75	0,00	310,18	7,00	7,60
		281,98	0,00	1924,30	0,00	195,50	0,00	310,18	7,00	4,60
		402,83	0,00	2061,75	0,00	0,00	0,00	310,18	7,00	7,50
		302,12	0,00	2061,75	0,00	69,82	0,00	310,18	7,00	3,80
		201,41	0,00	2061,75	0,00	139,64	0,00	310,18	7,00	2,10
		563,96	0,00	1924,30	0,00	0,00	0,00	310,18	28,00	22,00
		563,96	0,00	1443,22	390,99	0,00	0,00	310,18	28,00	22,40
		563,96	0,00	962,15	781,97	0,00	0,00	310,18	28,00	24,90
		563,96	0,00	481,07	1172,96	0,00	0,00	310,18	28,00	10,00
		563,96	0,00	0,00	1563,94	0,00	0,00	310,18	28,00	7,00
		402,83	0,00	2061,75	0,00	0,00	0,00	310,18	28,00	10,30
		402,83	0,00	1718,12	279,28	0,00	0,00	310,18	28,00	11,10
		402,83	0,00	1374,50	558,55	0,00	0,00	310,18	28,00	12,30
		402,83	0,00	1030,87	837,83	0,00	0,00	310,18	28,00	14,00
		402,83	0,00	687,25	1117,10	0,00	0,00	310,18	28,00	11,10
		402,83	0,00	343,62	1396,38	0,00	0,00	310,18	28,00	7,90
		402,83	0,00	0,00	1675,65	0,00	0,00	310,18	28,00	5,90
		563,96	0,00	1924,30	0,00	0,00	0,00	310,18	28,00	20,00
		422,97	0,00	1924,30	0,00	97,75	0,00	310,18	28,00	10,20

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)		
24	Agrawal <i>et al.</i> (2021)	281,98	0,00	1924,30	0,00	195,50	0,00	310,18	28,00	6,00		
		402,83	0,00	2061,75	0,00	0,00	0,00	310,18	28,00	10,30		
		302,12	0,00	2061,75	0,00	69,82	0,00	310,18	28,00	5,10		
		201,41	0,00	2061,75	0,00	139,64	0,00	310,18	28,00	3,10		
		563,96	0,00	1924,30	0,00	0,00	0,00	310,18	90,00	24,00		
		563,96	0,00	1443,22	390,99	0,00	0,00	310,18	90,00	24,10		
		563,96	0,00	962,15	781,97	0,00	0,00	310,18	90,00	27,30		
		563,96	0,00	481,07	1172,96	0,00	0,00	310,18	90,00	12,00		
		563,96	0,00	0,00	1563,94	0,00	0,00	310,18	90,00	8,00		
		402,83	0,00	2061,75	0,00	0,00	0,00	310,18	90,00	12,10		
		402,83	0,00	1718,12	279,28	0,00	0,00	310,18	90,00	12,30		
		402,83	0,00	1374,50	558,55	0,00	0,00	310,18	90,00	13,20		
		402,83	0,00	1030,87	837,83	0,00	0,00	310,18	90,00	15,90		
		402,83	0,00	687,25	1117,10	0,00	0,00	310,18	90,00	13,10		
		402,83	0,00	343,62	1396,38	0,00	0,00	310,18	90,00	9,20		
		402,83	0,00	0,00	1675,65	0,00	0,00	310,18	90,00	7,40		
		563,96	0,00	1924,30	0,00	0,00	0,00	310,18	90,00	24,00		
		422,97	0,00	1924,30	0,00	97,75	0,00	310,18	90,00	13,90		
		25	Moriconi <i>et al.</i> (2003)	281,98	0,00	1924,30	0,00	195,50	0,00	310,18	90,00	8,70
				402,83	0,00	2061,75	0,00	0,00	0,00	310,18	90,00	12,10
302,12	0,00			2061,75	0,00	69,82	0,00	310,18	90,00	6,10		
201,41	0,00			2061,75	0,00	139,64	0,00	310,18	90,00	4,50		
450,00	0,00			1350,00	0,00	0,00	0,00	225,00	7,00	47,00		
450,00	0,00			0,00	1350,00	0,00	0,00	300,00	7,00	28,00		
450,00	0,00			1350,00	0,00	0,00	0,00	225,00	14,00	59,00		
450,00	0,00			0,00	1350,00	0,00	0,00	300,00	14,00	31,00		

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
25	Moriconi <i>et al.</i> (2003)	450,00	0,00	1350,00	0,00	0,00	0,00	225,00	28,00	60,00
		450,00	0,00	0,00	1350,00	0,00	0,00	300,00	28,00	39,00
26	Mohammadhosseini <i>et al.</i> (2019)	550,00	0,00	1460,00	0,00	0,00	0,00	264,00	7,00	42,00
		550,00	0,00	1460,00	0,00	0,00	0,00	264,00	14,00	52,00
		550,00	0,00	1460,00	0,00	0,00	0,00	264,00	28,00	57,00
27	Amin <i>et al.</i> (2020)	277,00	0,00	870,00	0,00	0,00	0,00	139,00	28,00	24,61
		263,00	0,00	870,00	0,00	14,00	0,00	139,00	28,00	21,18
		277,00	0,00	783,00	0,00	87,00	0,00	139,00	28,00	25,79
28	Ramjan <i>et al.</i> (2018)	263,00	0,00	783,00	0,00	101,00	0,00	139,00	28,00	25,01
		720,81	0,00	1624,91	0,00	0,00	0,00	152,88	7,00	22,80
		720,81	0,00	1624,91	0,00	0,00	0,00	152,88	28,00	28,30
29	Singh <i>et al.</i> (2015)	598,84	0,00	1477,13	0,00	0,00	0,00	238,85	1,00	18,20
		598,84	0,00	1477,13	0,00	0,00	0,00	238,85	3,00	29,10
		598,84	0,00	1477,13	0,00	0,00	0,00	238,85	7,00	38,00
		598,84	0,00	1477,13	0,00	0,00	0,00	238,85	28,00	38,50
		2616,67	0,00	1570,00	0,00	0,00	0,00	1046,67	90,00	59,00
		2616,67	0,00	1570,00	0,00	0,00	0,00	1308,34	90,00	52,00
30	Bu <i>et al.</i> (2016)	2616,67	0,00	1570,00	0,00	0,00	0,00	1570,00	90,00	42,00
		1570,00	0,00	1570,00	0,00	0,00	0,00	628,00	90,00	65,00
		1570,00	0,00	1570,00	0,00	0,00	0,00	785,00	90,00	65,00
		157,00	0,00	1570,00	0,00	0,00	0,00	942,00	90,00	43,00
		1046,67	0,00	1570,00	0,00	0,00	0,00	418,67	90,00	70,00
		1046,67	0,00	1570,00	0,00	0,00	0,00	523,34	90,00	60,00
		1046,67	0,00	1570,00	0,00	0,00	0,00	628,00	90,00	53,00
		785,00	0,00	1570,00	0,00	0,00	0,00	314,00	90,00	73,00
785,00	0,00	1570,00	0,00	0,00	0,00	392,50	90,00	65,00		

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
30	Bu <i>et al.</i> (2016)	785,00	0,00	1570,00	0,00	0,00	0,00	471,00	90,00	58,00
		350,00	0,00	0,00	1500,00	0,00	0,00	270,00	7,00	10,61
31	Ning <i>et al.</i> (2015)	350,00	0,00	0,00	1500,00	0,00	0,00	270,00	28,00	20,96
		350,00	0,00	0,00	1500,00	0,00	0,00	270,00	60,00	24,04
		350,00	0,00	0,00	1500,00	0,00	0,00	270,00	90,00	25,80
		740,00	0,00	2035,00	0,00	0,00	0,00	420,00	28,00	31,00
32	Mahmod <i>et al.</i> (2017)	630,00	0,00	1260,00	0,00	0,00	0,00	252,00	7,00	40,97
		630,00	0,00	1260,00	0,00	0,00	0,00	252,00	14,00	49,83
		630,00	0,00	1260,00	0,00	0,00	0,00	252,00	28,00	54,05
		832,00	0,00	1032,00	0,00	0,00	0,00	333,00	26,00	76,90
33	Aadi <i>et al.</i> (2020)	778,00	0,00	1032,00	0,00	0,00	0,00	350,00	26,00	66,70
		731,00	0,00	1032,00	0,00	0,00	0,00	365,00	26,00	62,80
		689,00	0,00	1032,00	0,00	0,00	0,00	379,00	26,00	52,00
		828,00	0,00	1032,00	0,00	0,00	0,00	331,00	28,00	74,10
34	Li <i>et al.</i> (2020)	775,00	0,00	1032,00	0,00	0,00	0,00	349,00	28,00	62,70
		728,00	0,00	1032,00	0,00	0,00	0,00	364,00	28,00	49,90
		686,00	0,00	1032,00	0,00	0,00	0,00	377,00	28,00	47,30
		600,00	0,00	1800,00	0,00	0,00	0,00	238,00	7,00	40,30
35	Li <i>et al.</i> (2020)	600,00	0,00	1800,00	0,00	0,00	0,00	238,00	28,00	52,00
		600,00	0,00	1800,00	0,00	0,00	0,00	238,00	90,00	60,90
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	7,00	51,00
		450,00	0,00	135,00	0,00	0,00	0,00	225,00	7,00	37,00
36	Patel <i>et al.</i> (2020)	450,00	0,00	1350,00	0,00	0,00	0,00	225,00	28,00	67,00
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	28,00	58,00
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	7,00	34,65
37	Zhao <i>et al.</i> (2018)	450,00	0,00	1350,00	0,00	0,00	0,00	225,00	7,00	34,65
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	28,00	44,60
38	Demir <i>et al.</i> (2018)	450,00	0,00	1350,00	0,00	0,00	0,00	225,00	7,00	34,65
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	28,00	44,60

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
38	Demir <i>et al.</i> (2018)	450,00	0,00	1350,00	0,00	0,00	0,00	225,00	90,00	52,43
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	180,00	54,85
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	360,00	54,86
39	Nars <i>et al.</i> (2020)	587,00	0,00	1614,00	0,00	0,00	6,63	285,00	28,00	56,00
		587,00	0,00	1533,30	80,70	0,00	6,63	285,00	28,00	59,50
		587,00	0,00	1452,60	161,40	0,00	6,63	285,00	28,00	50,30
		587,00	0,00	1371,00	242,10	0,00	6,63	285,00	28,00	30,00
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	2,00	19,20
		450,00	0,00	1147,50	202,50	0,00	0,00	225,00	2,00	18,00
		450,00	0,00	945,00	405,00	0,00	0,00	225,00	2,00	15,90
40	Raini <i>et al.</i> (2020)	450,00	0,00	742,50	607,50	0,00	0,00	225,00	2,00	15,20
		450,00	0,00	135,00	1215,00	0,00	0,00	225,00	2,00	10,00
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	7,00	25,50
		450,00	0,00	1147,50	202,50	0,00	0,00	225,00	7,00	24,00
		450,00	0,00	945,00	405,00	0,00	0,00	225,00	7,00	23,80
		450,00	0,00	742,50	607,50	0,00	0,00	225,00	7,00	20,30
		450,00	0,00	135,00	1215,00	0,00	0,00	225,00	7,00	12,10
		450,00	0,00	1350,00	0,00	0,00	0,00	225,00	28,00	31,00
		450,00	0,00	1147,50	202,50	0,00	0,00	225,00	28,00	31,00
		450,00	0,00	945,00	405,00	0,00	0,00	225,00	28,00	29,10
		450,00	0,00	742,50	607,50	0,00	0,00	225,00	28,00	27,00
		450,00	0,00	135,00	1215,00	0,00	0,00	225,00	28,00	17,50
		41	Justo-Reimoso <i>et al.</i> (2018)	609,35	0,00	1409,08	0,00	0,00	0,00	273,39
610,76	0,00			1407,85	0,00	0,00	0,00	274,02	7,00	24,80
609,35	0,00			1409,08	0,00	0,00	0,00	273,39	14,00	32,00
610,76	0,00			1407,85	0,00	0,00	0,00	274,02	14,00	31,50

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
41	Justo-Reimoso <i>et al.</i> (2018)	609,35	0,00	1409,08	0,00	0,00	0,00	273,39	28,00	36,00
		610,76	0,00	1407,85	0,00	0,00	0,00	274,02	28,00	34,80
42	Azevedo <i>et al.</i> (2020)	282,51	239,46	1259,19	0,00	0,00	0,00	281,66	28,00	2,63
		282,51	239,46	944,40	260,99	0,00	0,00	290,11	28,00	2,73
		282,51	239,46	629,60	521,97	0,00	0,00	304,20	28,00	3,33
		282,51	239,46	0,00	1043,95	0,00	0,00	315,46	28,00	3,85
		450,00	0,00	1350,00	0,00	0,00	0,00	315,00	3,00	10,00
		450,00	0,00	1350,00	0,00	0,00	0,00	315,00	3,00	5,00
		450,00	0,00	1282,50	67,50	0,00	0,00	315,00	3,00	8,00
		450,00	0,00	1215,00	135,00	0,00	0,00	315,00	3,00	4,00
		450,00	0,00	1147,50	202,50	0,00	0,00	315,00	3,00	7,50
		450,00	0,00	1080,00	270,00	0,00	0,00	315,00	3,00	7,30
		450,00	0,00	1012,50	337,50	0,00	0,00	315,00	3,00	9,20
		450,00	0,00	1350,00	0,00	0,00	0,00	315,00	7,00	15,00
		450,00	0,00	1350,00	0,00	0,00	0,00	315,00	7,00	8,20
		43	Abadou <i>et al.</i> (2020)	450,00	0,00	1282,50	67,50	0,00	0,00	315,00
450,00	0,00			1215,00	135,00	0,00	0,00	315,00	7,00	9,80
450,00	0,00			1147,50	202,50	0,00	0,00	315,00	7,00	10,00
450,00	0,00			1080,00	270,00	0,00	0,00	315,00	7,00	11,80
450,00	0,00			1012,50	337,50	0,00	0,00	315,00	7,00	12,50
450,00	0,00			1350,00	0,00	0,00	0,00	315,00	28,00	20,00
450,00	0,00			1350,00	0,00	0,00	0,00	315,00	28,00	14,80
450,00	0,00			1282,50	67,50	0,00	0,00	315,00	28,00	17,00
450,00	0,00			1215,00	135,00	0,00	0,00	315,00	28,00	14,70
450,00	0,00			1147,50	202,50	0,00	0,00	315,00	28,00	14,80
		450,00	0,00	1080,00	270,00	0,00	0,00	315,00	28,00	15,30

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)		
43	<i>Abadou et al.</i> (2020)	450,00	0,00	1012,50	337,50	0,00	0,00	315,00	28,00	14,00		
		450,00	0,00	1350,00	0,00	0,00	0,00	315,00	90,00	24,80		
		450,00	0,00	1350,00	0,00	0,00	0,00	315,00	90,00	15,90		
		450,00	0,00	1282,50	67,50	0,00	0,00	315,00	90,00	19,80		
		450,00	0,00	1215,00	135,00	0,00	0,00	315,00	90,00	18,00		
		450,00	0,00	1147,50	202,50	0,00	0,00	315,00	90,00	18,10		
		450,00	0,00	1080,00	270,00	0,00	0,00	315,00	90,00	18,30		
		450,00	0,00	1012,50	337,50	0,00	0,00	315,00	90,00	18,10		
		190,00	0,00	1746,00	0,00	0,00	0,00	352,00	7,00	1,20		
		190,00	0,00	1571,00	143,00	0,00	0,00	298,00	7,00	1,90		
44	Kabeer e Vyas (2019)	190,00	0,00	1397,00	286,00	0,00	0,00	286,00	7,00	2,30		
		190,00	0,00	1222,00	429,00	0,00	0,00	289,00	7,00	2,60		
		190,00	0,00	1048,00	572,00	0,00	0,00	314,00	7,00	2,50		
		190,00	0,00	1746,00	0,00	0,00	0,00	352,00	28,00	2,80		
		190,00	0,00	1571,00	143,00	0,00	0,00	298,00	28,00	4,60		
		190,00	0,00	1397,00	286,00	0,00	0,00	286,00	28,00	5,00		
		190,00	0,00	1222,00	429,00	0,00	0,00	289,00	28,00	5,80		
		190,00	0,00	1048,00	572,00	0,00	0,00	314,00	28,00	5,60		
		45	<i>Selvaranjan et al.</i> (2021)	733,56	0,00	1036,76	0,00	0,00	0,00	365,73	7,00	16,00
				733,56	0,00	1036,76	0,00	0,00	0,00	365,73	28,00	23,00
400,00	0,00			1400,00	0,00	0,00	3,00	250,00	14,00	22,50		
46	<i>Chahour et al.</i> (2020)	400,00	0,00	980,00	420,00	0,00	3,00	250,00	14,00	27,00		
		400,00	0,00	700,00	700,00	0,00	3,00	250,00	14,00	32,00		
		400,00	0,00	420,00	980,00	0,00	3,00	250,00	14,00	27,20		
		400,00	0,00	0,00	1400,00	0,00	3,00	250,00	14,00	34,00		
		400,00	0,00	1400,00	0,00	0,00	3,00	250,00	28,00	29,00		

Tabela A – Banco de dados argamassa (continuação).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
46	Chahour <i>et al.</i> (2020)	400,00	0,00	980,00	420,00	0,00	3,00	250,00	28,00	29,20
		400,00	0,00	700,00	700,00	0,00	3,00	250,00	28,00	39,00
		400,00	0,00	420,00	980,00	0,00	3,00	250,00	28,00	34,50
		400,00	0,00	0,00	1400,00	0,00	3,00	250,00	28,00	36,00
		400,00	0,00	1400,00	0,00	0,00	3,00	250,00	56,00	32,50
		400,00	0,00	980,00	420,00	0,00	3,00	250,00	56,00	33,00
		400,00	0,00	700,00	700,00	0,00	3,00	250,00	56,00	38,00
		400,00	0,00	420,00	980,00	0,00	3,00	250,00	56,00	34,00
		400,00	0,00	0,00	1400,00	0,00	3,00	250,00	56,00	35,20
47	Chouhan <i>et al.</i> (2020)	225,00	0,00	1587,80	0,00	0,00	3,00	326,25	7,00	1,80
		225,00	0,00	1587,80	0,00	0,00	3,00	326,25	28,00	2,90
		225,00	0,00	1587,80	0,00	0,00	3,00	326,25	90,00	3,10
48	Safi <i>et al.</i> (2014)	730,51	0,00	372,40	0,00	0,00	10,60	276,00	2,00	42,00
		730,51	0,00	372,40	0,00	0,00	10,60	276,00	7,00	60,00
		730,51	0,00	372,40	0,00	0,00	10,60	276,00	28,00	71,00
49	Kabay <i>et al.</i> (2021)	608,00	0,00	1350,00	0,00	0,00	0,00	304,00	3,00	32,00
		608,00	0,00	1350,00	0,00	0,00	0,00	304,00	7,00	35,00
		608,00	0,00	1350,00	0,00	0,00	0,00	304,00	28,00	45,40
50	Yun <i>et al.</i> (2020)	1758,00	0,00	5273,00	0,00	0,00	0,00	879,00	7,00	39,60
		1758,00	0,00	5273,00	0,00	0,00	0,00	879,00	28,00	56,10
		1758,00	0,00	5273,00	0,00	0,00	0,00	879,00	90,00	58,20
51	Cheboub <i>et al.</i> (2020)	650,00	0,00	1300,00	0,00	0,00	0,00	273,00	3,00	44,00
		650,00	0,00	1300,00	0,00	0,00	0,00	273,00	7,00	45,50
		650,00	0,00	1300,00	0,00	0,00	0,00	273,00	28,00	54,10
		650,00	0,00	1300,00	0,00	0,00	0,00	273,00	62,00	55,00
		650,00	0,00	1300,00	0,00	0,00	0,00	273,00	91,00	63,00

Tabela A – Banco de dados argamassa (final).

Nº	Ref.	Cimento (kg)	Cal (kg)	Areia Natural (kg)	Areia Artificial/RCD (kg)	RBMG (kg)	Aditivo plastificante (kg)	Água (kg)	Dias	Resistência (MPa)
52	Huang <i>et al.</i> (2021)	450,00	0,00	1350,00	0,00	0,00	0,00	270,00	28,00	41,80
		450,00	0,00	1012,50	241,60	0,00	0,00	270,00	28,00	40,50
		450,00	0,00	675,00	483,20	0,00	0,00	270,00	28,00	37,00
		450,00	0,00	337,50	724,80	0,00	0,00	270,00	28,00	32,50
		450,00	0,00	0,00	966,40	0,00	0,00	270,00	28,00	30,00
		450,00	0,00	1012,50	241,60	0,00	0,00	297,30	28,00	49,80
		450,00	0,00	675,00	483,20	0,00	0,00	324,60	28,00	52,00
		450,00	0,00	337,50	724,80	0,00	0,00	351,90	28,00	62,50
		450,00	0,00	0,00	966,40	0,00	0,00	379,20	28,00	66,00
		231,10	93,30	1503,50	0,00	0,00	0,00	316,60	28,00	8,61
53	Ferreira <i>et al.</i> (2021)	207,50	83,80	1575,40	0,00	0,00	0,00	300,90	28,00	5,67
		170,20	137,50	1661,10	0,00	0,00	0,00	257,00	28,00	3,21
		210,60	85,10	0,00	1409,10	0,00	0,00	337,00	28,00	3,91
		189,70	76,60	0,00	1481,00	0,00	0,00	318,80	28,00	3,31
		157,20	127,00	0,00	1577,70	0,00	0,00	268,80	28,00	3,22
		210,60	85,10	0,00	1409,10	0,00	0,00	337,00	91,00	4,09
		189,70	76,60	0,00	1481,00	0,00	0,00	318,80	91,00	3,49
		157,20	127,00	0,00	1577,70	0,00	0,00	268,80	91,00	3,36

Fonte: o autor.