



**UNIVERSIDADE FEDERAL DE GOIÁS (UFG)/
UNIVERSIDADE FEDERAL DE CATALÃO (UFCAT) em implantação
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL**

**PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO E DO COEFICIENTE
DE PERMEABILIDADE DE CONCRETOS PERMEÁVEIS POR MEIO
DE APRENDIZAGEM DE MÁQUINAS**

ISABELLA CRISTINA QUEIROZ SILVA

Catalão

2023



UNIVERSIDADE FEDERAL DE GOIÁS
UNIDADE ACADÊMICA ESPECIAL DE ENGENHARIA

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 Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

ISABELLA CRISTINA QUEIROZ SILVA

3. Título do trabalho

**PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO E DO COEFICIENTE DE
PERMEABILIDADE DE CONCRETOS PERMEÁVEIS POR MEIO DE APRENDIZAGEM
DE MÁQUINAS**

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

Concorda com a liberação total do documento [X] 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(à) autor(a) e ao(à) 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 Sarmiento, Professor do Magistério Superior**, em 28/03/2023, às 14:02, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **ISABELLA CRISTINA QUEIROZ SILVA, Discente**, em 28/03/2023, às 14:55, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



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 **3628854** e o código CRC **862EF25B**.

ISABELLA CRISTINA QUEIROZ SILVA

**PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO E DO COEFICIENTE
DE PERMEABILIDADE DE CONCRETOS PERMEÁVEIS POR MEIO
DE APRENDIZAGEM DE MÁQUINAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil, da Faculdade de Engenharia, da Universidade Federal de Goiás (UFG) / Universidade Federal de Catalão (UFCAT) em implantação, como requisito para obtenção do título de Mestra em Engenharia Civil. Área de concentração: Estruturas e Construção Civil. Linha de pesquisa: Gestão, Tecnologia e Sustentabilidade na Construção Civil.

Orientador: Dr. Antover Panazzolo
Sarmiento

**Catalão
2023**

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

Silva, Isabella Cristina Queiroz
PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO E DO
COEFICIENTE DE PERMEABILIDADE DE CONCRETOS
PERMEÁVEIS POR MEIO DA APRENDIZAGEM DE MÁQUINAS /
Isabella Cristina Queiroz Silva. - 2023.
93, XCIII f.

Orientador: Prof. Dr. Antover Panazzolo Sarmento.
Dissertação (Mestrado) - Universidade Federal de Catalão,
Faculdade de Engenharia, Catalão, Programa de Pós-Graduação em
Engenharia Civil, Catalão, 2023.

Bibliografia. Anexos.

Inclui siglas, abreviaturas, símbolos, tabelas, lista de figuras, lista de tabelas.

1. Concreto Permeável. 2. Aprendizagem de Máquina. 3. Cubist. 4. svmRadial. 5. Desejabilidade. I. Sarmento, Antover Panazzolo, orient.
II. Título.

CDU 624



UNIVERSIDADE FEDERAL DE GOIÁS

UNIDADE ACADÊMICA ESPECIAL DE ENGENHARIA

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº **10** da sessão de Defesa de Dissertação de **ISABELLA CRISTINA QUEIROZ SILVA**, que confere o título de Mestra em Engenharia Civil, na área de concentração em Estruturas e Construção Civil.

"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."

No segundo dia do mês de março de dois mil e vinte e três a partir das dezesseis horas, na sala virtual (<https://meet.google.com/nfa-aokr-dhp>), realizou-se a sessão pública de Defesa de Dissertação intitulada "**PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO E DO COEFICIENTE DE PERMEABILIDADE DE CONCRETOS PERMEÁVEIS POR MEIO DE APRENDIZAGEM DE MÁQUINAS**" nas dependências da Universidade Federal de Catalão, onde os programas de pós-graduação stricto sensu em funcionamento encontram-se provisoriamente vinculados à Universidade Federal de Goiás, em virtude de procedimentos técnicos relacionados à CAPES, já sendo realizada a transferência da Biblioteca Digital de Dissertações e Teses (BDTD). Assim, justifica-se os nomes das instituições neste documento, uma no cabeçalho (UFG), outra no corpo do texto (UFCAT). Os trabalhos foram instalados pelo Orientador, **Professor Doutor ANTOVER PANAZZOLO SARMENTO (PPGEC/UFCAT)** com a participação dos demais membros da Banca Examinadora: **Professor Doutor MARCOS NAPOLEÃO RABELO**

(PPGMO/UFCAT), membro titular externo; e **Professor Doutor WANDERLEI MALAQUIAS PEREIRA JUNIOR (UFCAT)**, membro titular interno. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido a candidata **aprovada** pelos seus membros. Proclamados os resultados pelo Professor Doutor Antover Panazzolo Sarmiento, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos dois dias do mês de março de dois mil e vinte e três.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Antover Panazzolo Sarmiento, Professor do Magistério Superior**, em 03/03/2023, às 09:14, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Wanderlei Malaquias Pereira Junior, Professor do Magistério Superior**, em 03/03/2023, às 17:20, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Napoleão Rabelo, Professor do Magistério Superior**, em 06/03/2023, às 09:00, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



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 **3566775** e o código CRC **433250DE**.

Referência: Processo nº 23070.004833/2023-16

SEI nº 3566775

Aos meus amados pais Jairon e Fernanda,
minha irmã Letícia e ao Guilherme,
pelo amor e apoio incondicional.

AGRADECIMENTOS

À Deus pela oportunidade e por me fazer capaz de superar todos os desafios.

Aos meus pais que são a minha maior fonte de amor e inspiração. Obrigada pela paciência, por sempre acreditarem em mim e serem meu porto seguro. É tudo para vocês e por vocês.

À minha irmã (naninha) pelo companheirismo e incentivo.

Ao Guilherme pela paciência, carinho e apoio.

Ao meu padrinho Tiagua e minha madrinha Eleusa por todo amor e cuidado.

Ao meu orientador Antover Panazzolo Sarmento pela oportunidade, ajuda, apoio, paciência, incentivo e compreensão.

Ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Catalão e seus servidores, em especial aos professores Ed Carlo Rosa Paiva e Enio José Pazini Figueiredo e ao técnico Sérgio Henrique Fernandes Mundim.

Aos meus colegas de mestrado que trilharam esse caminho comigo, especialmente a Daiane que tanto me ajudou.

Aos meus afilhados Arthur, Maria Luiza e Davi que sempre foram lugar de amor e carinho.

Às minhas amigas, Thaynara, Caroline, Elis e Maria Clara, e ao meu cunhado Kleyton pelo apoio.

À todos os meus familiares e amigos que me apoiaram e me incentivaram, contribuindo para a conclusão de mais essa etapa da minha vida.

À todos aqueles que fizeram parte da minha trajetória como estudante.

Aos orientandos do professor Antover pela ajuda e disponibilidade.

À FAPEG pelo apoio financeiro.

SUMÁRIO

| | |
|--|------|
| LISTA DE FIGURAS | vi |
| LISTA DE QUADROS E TABELAS | vii |
| LISTA DE SÍMBOLOS | ix |
| LISTA DE ABREVIATURAS E SIGLAS | x |
| RESUMO | xiii |
| ABSTRACT | xiv |
| NOTA | xv |
| 1. INTRODUÇÃO | 16 |
| 1.1 OBJETIVO GERAL | 17 |
| 1.2 OBJETIVOS ESPECÍFICOS | 17 |
| 2. CONCRETO PERMEÁVEL | 18 |
| 2.1 CARACTERÍSTICAS E PROPRIEDADES DO CONCRETO PERMEÁVEL | 19 |
| 2.2.1 Cimento Portland | 21 |
| 2.2.2 Agregado graúdo | 24 |
| 2.2.3 Aditivo | 25 |
| 2.3 TRAÇOS DE CONCRETO PERMEÁVEL | 26 |
| 3. APRENDIZAGEM DE MÁQUINA | 30 |
| 3.1 MODELOS DE APRENDIZAGEM DE MÁQUINA | 31 |
| 3.1.1 K-Neighbor Regressor (KNN) | 32 |
| 3.1.2 Bayesian Regularization Neural Network (BRNN) | 34 |
| 3.1.3 Boosted Tree (<i>Blackboost</i>) | 35 |
| 3.1.4 Support Vector Machines (<i>svmRadial</i>) | 35 |
| 3.1.5 Random Forest | 38 |
| 3.1.6 <i>Cubist</i> | 40 |
| 3.1.7 Relevance Vector Machines (<i>rvmRadial</i>) | 41 |
| 3.2 APRENDIZAGEM DE MÁQUINA NA PREDIÇÃO DE PROPRIEDADES DE CONCRETO | 42 |
| 4. FUNÇÃO DE DESEJABILIDADE | 44 |
| 5. MATERIAIS E MÉTODOS | 46 |
| 5.1 COLETA DE DADOS | 46 |
| 5.2 LINGUAGEM DE PROGRAMAÇÃO | 47 |
| 5.3 ANÁLISE DESCRITIVA DOS DADOS | 48 |
| 5.4 VERIFICAÇÃO DA CORRELAÇÃO DAS VARIÁVEIS | 49 |
| 5.5 AVALIAÇÃO INICIAL DO DESEMPENHO DOS MODELOS DE AM | 50 |

| | | |
|---------|--|----|
| 5.6 | CALIBRAÇÃO DOS PARÂMETROS DE AJUSTE | 51 |
| 5.7 | FERRAMENTAS DE AVALIAÇÃO DO DESEMPENHO DO MODELO..... | 51 |
| 5.7.1 | Coeficiente de determinação – R^2 | 52 |
| 5.7.2 | Raiz quadrada do erro médio – RMSE | 52 |
| 5.7.3 | Erro absoluto médio – MAE..... | 52 |
| 5.8 | FUNÇÃO DE DESEJABILIDADE | 53 |
| 5.9 | VALIDAÇÃO DO MELHOR MODELO EM LABORATÓRIO | 54 |
| 5.9.1 | Materiais | 54 |
| 5.9.1.1 | Cimento Portland | 54 |
| 5.9.1.2 | Agregado graúdo | 54 |
| 5.9.1.3 | Aditivo superplastificante..... | 55 |
| 5.9.2 | Preparação das amostras e testes..... | 55 |
| 6. | RESULTADOS E DISCUSSÕES | 56 |
| 6.1 | CARACTERIZAÇÃO DOS DADOS | 56 |
| 6.2 | ANÁLISE DOS DADOS..... | 56 |
| 6.3 | VERIFICAÇÃO DE CORRELAÇÃO ENTRE AS VARIÁVEIS..... | 57 |
| 6.4 | AVALIAÇÃO DE DESEMPENHO DOS MODELOS DE AM..... | 58 |
| 6.5 | CALIBRAÇÃO DOS PARÂMETROS DE AJUSTE | 60 |
| 6.5.1 | Determinação da separação entre treino e teste e do método de controle..... | 61 |
| 6.5.2 | Determinação do número de comitês e vizinhos para o modelo <i>cbist</i> | 63 |
| 6.5.3 | Determinação do sigma e custo para o modelo <i>svmRadial</i> | 63 |
| 6.5.4 | Importância das variáveis de entrada e saída..... | 64 |
| 6.5.5 | Avaliação dos algoritmos após calibração dos parâmetros | 65 |
| 6.6 | DESEJABILIDADE..... | 67 |
| 6.7 | VALIDAÇÃO DO MODELO | 69 |
| 6.7.1 | <i>Slump test</i> | 70 |
| 6.7.2 | Ensaio de resistência à compressão..... | 71 |
| 6.7.3 | Comparação entre os valores preditos e os valores reais obtidos em laboratório | |
| | 73 | |
| 6.7.4 | Permeabilidade..... | 76 |
| 7. | CONSIDERAÇÕES FINAIS..... | 77 |
| 7.1 | SUGESTÕES PARA TRABALHOS FUTUROS..... | 78 |
| 8. | REFERÊNCIAS BIBLIOGRÁFICAS | 79 |
| | ANEXO A – BANCO DE DADOS (ZHANG <i>et al.</i> , 2020)..... | 90 |

LISTA DE FIGURAS

| | |
|---|----|
| FIGURA 3.1 – Gráfico dos modelos testados e os valores de coeficiente de determinação (R-Squared) por validação cruzada de 10 vezes e o conjunto de teste, para a predição da solubilidade | 31 |
| FIGURA 3.2 – Gráficos de coordenadas paralelas para R^2 com validação cruzada em diferentes modelos. Cada linha representa os resultados para um conjunto comum de validação cruzada | 32 |
| FIGURA 3.3 – Uma ilustração de K-vizinhos mais próximos (KNN)..... | 33 |
| FIGURA 3.4 – Influência da escolha do k no estimador de k-vizinhos mais próximos (KNN) | 34 |
| FIGURA 3.5 – Uma ilustração de vetores de suporte (SVM)..... | 36 |
| FIGURA 3.6 – Separação das classes por um hiperplano | 36 |
| FIGURA 3.7 – Algoritmo SVM Kernel Polinomial e Radial | 37 |
| FIGURA 3.8 – Princípio do modelo RF..... | 39 |
| FIGURA 3.9 – Ajustes de árvore de regressão e florestas aleatórias para diferentes conjuntos de dados vindo da mesma função de regressão..... | 39 |
| FIGURA 4.1 – Possibilidades da função de desejabilidade | 45 |
| FIGURA 5.1 – Metodologia para a predição da resistência à compressão e do coeficiente de permeabilidade do concreto permeável | 46 |
| FIGURA 5.2 – Agregado graúdo “brita 1” (a) e “brita 0” (b)..... | 54 |
| FIGURA 5.3 – Composição granulométrica do agregado graúdo | 55 |
| FIGURA 6.1 – Análise de correlação entre as variáveis de entrada e as variáveis resistência à compressão e coeficiente de permeabilidade | 57 |
| FIGURA 6.2 – Análise comparativa entre os algoritmos em relação a resistência à compressão ... | 59 |
| FIGURA 6.3 – Análise comparativa entre os algoritmos em relação ao coeficiente de permeabilidade | 60 |
| FIGURA 6.4 – Melhor ajuste para o modelo <i>cubist</i> | 63 |
| FIGURA 6.5 – Melhor ajuste para o modelo <i>svmRadial</i> | 64 |
| FIGURA 6.6 – Importância de cada variável em relação ao modelo <i>cubist</i> | 64 |
| FIGURA 6.7 – Importância de cada variável em relação ao modelo <i>svmRadial</i> | 65 |
| FIGURA 6.8 – Resistência à compressão real <i>versus</i> Resistência à compressão observada..... | 66 |
| FIGURA 6.9 – Coeficiente de permeabilidade real <i>versus</i> Coeficiente de permeabilidade observada | 67 |
| FIGURA 6.10 – <i>Slump test</i> traço 3..... | 70 |
| FIGURA 6.11 – Corpos de prova moldados em laboratório | 71 |
| FIGURA 6.12 – Comparação entre os valores médios de resistência à compressão | 72 |
| FIGURA 6.13 – Corpos de prova após serem rompidos | 74 |

LISTA DE QUADROS E TABELAS

| | |
|---|----|
| QUADRO 2.1 – Resistência mecânica e espessura mínima do revestimento permeável segundo seu tipo e solicitação..... | 21 |
| QUADRO 2.2 – Limites de composição do cimento Portland NBR 16697 (ABNT, 2018) | 23 |
| QUADRO 2.3 – Proporção típica de materiais para concreto permeável..... | 26 |
| QUADRO 2.4 – Resumo de traços para concreto permeável de dados da literatura..... | 28 |
| QUADRO 5.1 – Bibliotecas utilizadas | 48 |
| QUADRO 5.2 – Parâmetros utilizados para a análise descritiva..... | 49 |
| QUADRO 5.3 – Parâmetros de ajuste de cada modelo | 50 |
| QUADRO A – Banco de dados concreto permeável..... | 90 |
| | |
| TABELA 5.1 – Parâmetros verificados no trabalho de Zhang <i>et al.</i> , 2020..... | 47 |
| TABELA 6.1 – Análise descritiva das variáveis do banco de dados utilizados para concreto permeável | 56 |
| TABELA 6.2 – Coeficiente de determinação em relação a resistência à compressão | 59 |
| TABELA 6.3 – Coeficiente de determinação em relação ao coeficiente de permeabilidade | 60 |
| TABELA 6.4 – Erro absoluto médio (MAE) para o modelo <i>cube</i> considerando diferentes combinações de dados para treino e teste, na predição da resistência a compressão | 61 |
| TABELA 6.5 – Raiz quadrada do erro médio (RMSE) para o modelo <i>cube</i> considerando diferentes combinações de dados para treino e teste, na predição da resistência a compressão | 61 |
| TABELA 6.6 – Coeficiente de determinação R ² (Rsquared) para o modelo <i>cube</i> considerando diferentes combinações de dados para treino e teste, na predição da resistência a compressão | 61 |
| TABELA 6.7 – Erro absoluto médio (MAE) para o modelo <i>svmRadial</i> considerando diferentes combinações de dados para treino e teste, na predição do coeficiente de permeabilidade..... | 62 |
| TABELA 6.8 – Raiz quadrada do erro médio (RMSE) para o modelo <i>svmRadial</i> considerando diferentes combinações de dados para treino e teste na predição do coeficiente de permeabilidade | 62 |
| TABELA 6.9 – Coeficiente de determinação R ² (Rsquared) para o modelo <i>svmRadial</i> considerando diferentes combinações de dados para treino e teste na predição do coeficiente de permeabilidade | 62 |
| TABELA 6.10 – Resumo final do modelo <i>cube</i> com os parâmetros ajustados..... | 66 |
| TABELA 6.11 – Resumo final do modelo <i>svmRadial</i> com os parâmetros ajustados | 67 |
| TABELA 6.12 – Desejabilidades – Traços ideais | 68 |
| TABELA 6.13 – Traços práticos adaptados dos traços da desejabilidade para as condições possíveis de serem executadas no laboratório..... | 69 |
| TABELA 6.14 – <i>Slump test</i> | 70 |
| TABELA 6.15 – Resultado do ensaio de resistência à compressão | 72 |

| | |
|--|----|
| TABELA 6.16 – Comparação entre os resultados preditos nos traços práticos e os resultados obtidos para resistência à compressão | 72 |
|--|----|

LISTA DE SÍMBOLOS

x_i ; x_j : são duas instâncias representadas por vetores no espaço \mathbb{R}^d ;

x_i^l ; x_j^l : são elementos desses vetores, que correspondem aos valores da coordenada l (atributos).

$|\rho|$: coeficiente de correlação amostral de Pearson

y_i : valor medido experimental;

\hat{y}_i : valor estimado;

\bar{y} : média dos valores observados;

Θ_k : vetores aleatórios;

\hat{Y}_{par} Combinação;

α Suavização;

$\hat{y}^{(k)}$ Previsão do modelo atual;

$\hat{y}^{(p)}$ Previsão do modelo pai.

LISTA DE ABREVIATURAS E SIGLAS

ABCP – Associação Brasileira de Cimento Portland;

ABNT – Associação Brasileira de Normas Técnicas;

A/C; AC – Relação água/cimento;

ACI – American Concrete Institute;

AGCIM – Relação agregado/cimento;

AG.M/AG.G – Relação agregado miúdo/agregado graúdo;

AG/CIM – Relação agregado/cimento;

AM – Aprendizagem de máquina;

AMPL – Amplitude;

ANN – Redes Neurais Artificiais;

ANFIS – Sistema de Inferência Neuro-Fuzzy Adaptativo;

AS1012.9 – Métodos de teste de concreto Testes de resistência à compressão, método 9;

AS1012.14 – Métodos de teste de concreto Testes de resistência à compressão, método 14;

ASSIM – Assimetria;

BAS – Algoritmo de Busca De Antenas De Besouros;

BC – Baixo calor de hidratação;

BRNN – Bayesian Regularization Neural Network;

C – Custo;

CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior;

CART – Árvore de Classificação E Regressão;

CJJ/T – Especificação técnica para pavimento de concreto de cimento permeável;

CP – Cimento Portland;

CP – Corpo de prova

CP B – Cimento Portland branco estrutural e não estrutural;

CP I – Cimento Portland comum;

CP I – S – Cimento Portland comum com adição;

CP II – E – Cimento Portland composto com escória;

CP II – F – Cimento Portland composto com filer;

CP II – Z – Cimento Portland composto com pozolana;

CP III – Cimento Portland composto de alto-forno;

CP IV – Cimento Portland Pozolânico;

CP V ARI – Cimento Portland de alta resistência inicial;

CPC – Cimento Portland Comum;

CURT – Curtose;

CV – Coeficiente de variação;
D1 – Desejabilidade 1;
D2 – Desejabilidade 2;
D3 – Desejabilidade 3;
DIAM – Diâmetro do agregado;
EP – Erro padrão;
ESVR – Máquinas Uma Regressão de Vetor De Suporte Evoluída;
IBGE – Instituto Brasileiro de Geografia e Estatística;
IV – índice de variação;
KNN – *K-Neighbor Regressor* ou K-vizinhos mais próximos;
MAE – Erro Médio Absoluto;
MARS – Modelos de *Splines* de Regressão Adaptativo Multivariada;
MÁX – Máximo;
MÍN – Mínimo;
MOLSSVR – Método de Regressão Vetorial de Suporte de Mínimos Quadrados com Várias Saídas;
NBR – Norma Brasileira;
NRMCA – Associação Nacional de Concreto Misto Pronto;
Nº dados – Número de dados;
PCA – Associação de Cimento Portland;
PLS – Mínimos Quadrados Parciais;
PERM – Coeficiente de permeabilidade;
Q_{1,25%} – Primeiro quartil;
Q_{3,75%} – Terceiro quartil;
RBF – *Radial Basis Function* ou Função de Base Radial;
RF – Random Forest ou Florestas aleatórias;
Rsquared – Coeficiente de determinação;
RMSE – Raiz Quadrada do Erro Médio;
RS – Resistente ao sulfato;
RVM – Máquina de Vetores de Relevância;
R² – Coeficiente de determinação;
SD – Desvio padrão;
SP – Superplastificante;
SVM – Máquina de Vetor Suporte;
SVMP – Máquina de Vetor Suporte Polinomial;
SVMR – Máquina de Vetor Suporte Radial;
SVR – Regressão Vetorial de Suporte;
TP1 – Traço Prático 1;

TP2 – Traço Prático 2;

TP3 – Traço Prático 3;

VAR – Variância;

XGB – Gradiente Extremo

RESUMO

SILVA, I. C. Q. **Predição da resistência à compressão e do coeficiente de permeabilidade de concretos permeáveis por meio de aprendizagem de máquina.** Catalão. Dissertação (Mestrado) - Unidade Acadêmica Especial de Engenharia, Regional Catalão, Universidade Federal de Goiás, 2023, 92 p.

Devido a limitação dos sistemas de drenagem e a impermeabilização dos solos, as chances de ocorrerem inundações, devido ao aumento do escoamento superficial são elevadas em dias de chuva. O aumento de áreas impermeáveis afeta também a recarga do lençol freático, pois dificulta a infiltração da água no solo. Para atenuar os transtornos citados, surge, como alternativa aos sistemas de drenagem tradicionais, o concreto permeável, que é um material poroso que possibilita a penetração da água entre suas camadas. Devido ao seu alto volume de vazios o concreto permeável acaba apresentando propriedades físicas inferiores quando comparados ao concreto convencional, necessitando de estudos que busquem otimizar esses aspectos. Métodos de aprendizagem de máquina demonstram sucesso em estudos preditivos de propriedades do concreto permeável. Através do ajuste dos hiperparâmetros de cada modelo, é possível ainda melhorar os algoritmos e aumentar a precisão dos resultados. Além disso, a ferramenta função de desejabilidade otimiza respostas de forma simultânea. O banco de dados utilizado foi o disponível no trabalho de Zhang *et al.* (2020) e é composto por diferentes proporções de misturas de concreto permeável, levando em conta a relação água/cimento, diâmetro do agregado e relação agregado/cimento, e suas respectivas respostas, resistência à compressão e coeficiente de permeabilidade. Os dados foram processados, utilizando a linguagem R, em busca do modelo que apresentasse melhor comportamento. Os algoritmos foram ajustados para sua otimização e a função de desejabilidade foi empregada em busca da melhor configuração, maximizando as respostas. Para a resistência à compressão do concreto permeável, o modelo que apresentou melhor resultado foi o *cubist* que, após o ajuste, apresentou valor de R^2 igual a 0,9994 para treino e de 0,9987 para teste. Para o coeficiente de permeabilidade, o melhor modelo foi o *svmRadial*, com valor de R^2 igual a 0,9887 para treino e 0,9719 para teste, após os ajustes. As desejabilidades requeridas foram D1, máximo valor de resistência à compressão e máximo valor de coeficiente de permeabilidade, D2, valor de resistência à compressão alvo de 20 MPa e valor do coeficiente de permeabilidade alvo de 1 mm/s, e D3, valor de resistência à compressão alvo 20 MPa e máximo valor de coeficiente de permeabilidade, com no mínimo 1 mm/s. Os resultados de desejabilidade global foram, respectivamente, 0,7731, 0,9618 e 0,9289, demonstrando que a técnica estatística é capaz de aperfeiçoar e direcionar estudos, encontrando o melhor resultado possível para cada combinação, mitigando despesas relacionadas a testes laboratoriais.

Palavras-chave: Concreto Permeável; Aprendizagem de Máquina; *Cubist*, *svmRadial*; Desejabilidade.

ABSTRACT

SILVA, I. C. Q. **Predição da resistência à compressão e do coeficiente de permeabilidade de concretos permeáveis por meio de aprendizagem de máquina.** Catalão. Dissertação (Mestrado) - Unidade Acadêmica Especial de Engenharia, Regional Catalão, Universidade Federal de Goiás, 2023, 92 p.

Due to the limitation of drainage systems and soil sealing, the chances of flooding occurring due to increased surface runoff are high on days of peak rainfall. The increase in impermeable areas also affects the recharge of the water table, as it hinders the infiltration of water into the soil. To mitigate the aforementioned disorders, as an alternative to traditional drainage systems, pervious concrete appears, which is a porous material that allows water to penetrate between its layers. Due to its high volume of voids, pervious concrete ends up presenting inferior physical properties when compared to conventional concrete, requiring studies that seek to optimize these aspects. Machine learning methods demonstrate success in predictive studies of pervious concrete properties. By adjusting the hyperparameters of each model, it is possible to further optimize the algorithms and increase the accuracy of the predicted results. Machine learning allows a trained model to seek results according to previously desired parameters. In addition, the desirability function tool optimizes responses simultaneously. The database used was selected. A database was used in the work of Zhang *et al.* (2020) and is composed of different proportions of pervious concrete mixtures, taking into account the water/cement ratio, aggregate diameter and aggregate/cement ratio, and their respective responses that study the two main properties of pervious concrete, compressive strength and permeability coefficient. The data were processed, using the R language, in search of the model that presented the best behavior and optimized. The algorithms were adjusted for their optimization and the desirability function was used in search of the best configuration, maximizing the responses. For the compressive strength of pervious concrete, the model that presented the best result was the cubist model which, after adjustment, presented a value of R^2 equal to 0.9994 for training and 0.9987 for testing. For the permeability coefficient, the best model was svmRadial, with an R^2 value equal to 0.9887 for training and 0.9719 for testing, after adjustments. The required desirabilities were D1, maximum compressive strength value and maximum permeability coefficient value, D2, target compressive strength value of 20 MPa and target permeability coefficient value of 1 mm/s, and D3, strength value at target compression 20 MPa and maximum permeability coefficient value, with at least 1 mm/s. The global desirability results were, respectively, 0.7731, 0.9618 and 0.9289, demonstrating that the statistical technique is capable of improving and directing studies, finding the best possible result for each combination, mitigating expenses related to laboratory tests.

Keywords: Pervious Concrete; Machine Learning; *Cubist*, *svmRadial*; Desirability.

NOTA

Os programas de pós-graduação stricto sensu em funcionamento na Universidade Federal de Catalão (UFCAT), em virtude de procedimentos técnicos relacionados à Capes, continuam provisoriamente vinculados à Universidade Federal de Goiás (UFG), por isso todos os elementos pré-textuais do trabalho apresentado estão identificados como Universidade Federal de Goiás/Universidade Federal de Catalão em implantação, em função da migração da Biblioteca Digital Brasileira de Teses e Dissertações (BDTD) ter ocorrido a partir de 16 de agosto de 2021, assim como pelo fato de as pesquisas e os produtos serem realizados na UFCAT.

1. INTRODUÇÃO

O processo de urbanização brasileiro, ocorreu, majoritariamente, de maneira desordenada. Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2003), entre 1901 e 2000 a população brasileira cresceu, aproximadamente, 950%, sendo que a partir de 1950, o volume de pessoas nas cidades foi intensificado devido a industrialização.

Como Tucci (2003) ressalta que o elevado crescimento urbano acontece especialmente em zonas periféricas, em áreas de mananciais e de risco. Sem o devido planejamento e infraestrutura, a ocupação desses territórios ocasiona problemas graves relacionados a drenagem urbana (alagamentos e inundações) e de saneamento (abastecimento e tratamento da água e esgoto).

Com o aumento das construções urbanas e, conseqüentemente, das áreas impermeáveis, a água que antes, infiltrava no solo, escoava superficialmente. Desse modo, é necessário a construção de condutos para guiar essa água de volta a natureza (TUCCI, 2007), entretanto, obras desse porte demandam tempo e altos investimentos.

Como medida auxiliar aos sistemas de drenagem, surge o concreto permeável, um material com alto volume de vazios, que apresenta poros interligados, que possibilita o transporte de fluidos (DEO; NEITHATATH, 2010). Ainda segundo os autores, o concreto permeável apresenta alta capacidade de absorver águas pluviais, reabastecendo o lençol freático e conservando recursos hídricos naturais.

Além dos benefícios citados relacionados a diminuição do escoamento superficial e recarga das águas subterrâneas, a utilização de pavimentos de concreto permeável age como filtro, minimizando poluentes sólidos presentes na água, maior resistência na derrapagem, e mitiga efeitos relacionados a ilhas de calor (GHAFOORI, 1995; PARK; TIA, 2004; KEVERN; SCHAEFER; WANG, 2009; KEVERN; HASELBACH; SCHAEFER, 2012; GAEDICKE; MARINES; MIANKODILA, 2014).

A estratégia de utilizar concreto permeável como pavimento é uma medida compensatória, sustentável de baixo impacto que apresenta benefícios ambientais, econômicos e sociais. Entretanto, devido a sua alta porosidade, este tipo de concreto apresenta propriedades inferiores comparadas ao concreto convencional, limitando sua aplicação (ZHONG; WILLE, 2016).

Sun *et al.* (2019) destacam que a resistência à compressão e o coeficiente de permeabilidade são as duas principais propriedades do concreto permeável. Para a obtenção das mesmas, a maioria dos autores optam pela utilização de equações empíricas e testes laboratoriais.

Zhong, Leng e Poon (2018) salientam que essas propriedades não podem ser obtidas de forma precisa e confiável, uma vez que os poros presentes no concreto se distribuem de forma completamente aleatória. Testes laboratoriais, embora sejam mais precisos, exigem um alto número de amostras, tempo e elevam os custos (SUN *et al.*, 2019).

Como alternativa que minimize gastos, aumente a precisão e otimizem as propriedades do concreto permeável, modelos de aprendizagem de máquina, que são capazes de criar relações confiáveis entre variáveis de entrada e saída, por meio da inteligência artificial, aumentando o desempenho do

concreto permeável através de um modelo preditivo antes do seu processo de fabricação (ZHANG *et al.*, 2020), têm sido empregados com sucesso em estudos de predição de propriedades do concreto permeável (ADEWUMI *et al.*, 2016; SUN *et al.*, 2019; CHEN; ZHAO; BIE, 2020; NARENDULA; ADEPU, 2020; ZHANG *et al.*, 2020; AHMED *et al.*, 2021).

Além de ser possível prever propriedades do concreto com a aprendizagem de máquina é possível ainda otimizar seus resultados. A função de desejabilidade, por exemplo, é uma ótima ferramenta que busca solucionar problemas de otimização de múltiplas respostas, como no caso de misturas de concreto que envolvem diversos fatores (GOETHALS; CHO, 2012). Sonebi e Bassuoni (2013), por exemplo, aplicaram a função a procura de traços de misturas de concreto permeável que melhor se adequassem as condições requeridas.

A aplicação de aprendizagem de máquina na indústria da construção é uma forma de construção inteligente (GARCIA *et al.*, 2022), que busca prever, controlar e melhorar características e propriedades do concreto permeável de forma ágil e econômica, ajustando seus parâmetros segundo padrões previamente estabelecidos.

1.1 OBJETIVO GERAL

Determinar o melhor modelo para a predição de resistência à compressão e do coeficiente de permeabilidade de concretos permeáveis, por meio de técnicas de aprendizagem de máquina, otimizando seus resultados por meio de ajustes e da função de desejabilidade.

1.2 OBJETIVOS ESPECÍFICOS

- Fazer uma revisão bibliográfica sobre o tema;
- Realizar um levantamento de dados a fim de colher informações sobre traços, resistência à compressão e coeficiente de permeabilidade de concretos permeáveis;
- Definir e processar os dados brutos, utilizando a linguagem R, para testá-los com diferentes algoritmos, para que seja possível verificar qual deles apresenta o melhor resultado;
- Encontrar a melhor separação de dados de treino e teste e os hiperparâmetros que melhor ajustam os modelos;
- Realizar a predição da resistência à compressão e coeficiente de permeabilidade de diferentes traços de concreto permeável;
- Otimizar os traços utilizando a função de desejabilidade;
- Executar a validação dos modelos otimizados em laboratório.

2. CONCRETO PERMEÁVEL

O concreto permeável é um material poroso composto por cimento Portland, água, agregado graúdo e, em alguns casos, uma porcentagem de agregado miúdo e outros aditivos e/ou adições especiais (HUANG *et al.*, 2010; IBRAHIM *et al.*, 2014; NGUYEN *et al.*, 2014; AHMED *et al.*, 2021).

Basicamente sua composição é de pasta de cimento e agregados graúdos.

A NBR 16416 (ABNT, 2015) define o concreto permeável como sendo um concreto que possui vazios interligados que possibilita que a água escoe por dentro de sua estrutura pela ação da gravidade. O concreto permeável é um tipo de concreto especial que apresenta em sua estrutura poros altamente conectados (YAHIA; KABAGIRE, 2014).

Segundo a bibliografia, o uso desse tipo de concreto é datado desde 1852 no Reino Unido, sendo mencionado novamente na literatura em 1923. Ao longo dos anos, especialmente após a Segunda Guerra Mundial, seu uso foi expandido, podendo ser utilizado em diversas áreas da engenharia, sendo sua aplicação como pavimento a mais difundida (ACI, 2010)

O concreto permeável utilizado como pavimento permite a percolação da água por entre sua estrutura, facilitando assim a absorção de águas provenientes de chuva, diminuindo o escoamento superficial, evitando possíveis alagamentos em dias de eventos extremos de precipitação (BATEZINI, 2013).

O uso do concreto permeável traz inúmeras vantagens para o meio ambiente, como por exemplo, redução do escoamento superficial, controle da poluição das águas pluviais na fonte, eliminação ou redução do esgoto pluvial, diminuição ou eliminação da necessidade de áreas de retenção de água em estacionamentos, permitindo que a água chegue diretamente nas raízes das árvores, entre outras (ACI, 2010).

O concreto permeável utilizado como revestimento pode ser executado, segundo a NBR 16416 (ABNT, 2015), com as seguintes tipologias:

- Revestimento de peças de concreto convencional com juntas alargadas;
- Revestimento de peças de concreto com áreas vazadas;
- Revestimento de peças de concreto permeável;
- Revestimento de pavimento de placas de concreto permeável;
- Revestimento de pavimento de concreto permeável.

A 522R-10 (ACI, 2010) sugere alguns tipos de aplicações do revestimento de concreto permeável:

- Parques e estacionamentos;
- Camadas de drenagem em shoppings;
- Pisos de estufas;
- Calçadas;

- Decks de piscinas, entre outros.

2.1 CARACTERÍSTICAS E PROPRIEDADES DO CONCRETO PERMEÁVEL

As propriedades do concreto permeável dependem, especialmente de sua porosidade, que depende do teor de cimento, da relação água/cimento, do nível de compactação e da gradação e qualidade de seus agregados (ACI, 2010).

A norma americana 522R-10 (ACI, 2010) destaca as principais propriedades físicas do concreto permeável:

- Resistência à compressão;
- Resistência à flexão;
- Volume de vazios/densidade;
- Tamanho dos poros;
- Taxa de percolação da água;
- Durabilidade.

Como destacam Sun *et al.* (2019), a resistência mecânica e o coeficiente de permeabilidade do concreto permeável são as propriedades mais importantes do material, e são parâmetros básicos de estudos para sua utilização como pavimento, como sugere a NBR 16416 (ABNT, 2015), que exige equilíbrio entre elas.

A grande porcentagem de vazios, entre 15 e 35%, como mencionam 522R-10 (ACI, 2010), Yahia e Kabagire (2014), Sonebi, Bassuoni e Yahia (2016), Chen *et al.* (2019) e Le *et al.* (2022), propicia a infiltração da água no concreto, mas acaba afetando de forma negativa sua resistência mecânica, limitando seu uso (TENNIS; LEMING; AKERS, 2004; HUANG *et al.*, 2010; LIAN; ZHUGE; BEECHAM, 2011; SONEBI; BASSUONI; YAHIA, 2016; CHANDRAPPA; BILIGIRI, 2016; SUN; LIN; VOLLPRACHT, 2018; ZHANG *et al.*, 2020).

Ozbek *et al.* (2013) afirmam que no concreto poroso as ligações entre a pasta de cimento e os agregados são muito finas e tendem a ser fracas e, por isso, seu comportamento é inferior ao concreto convencional. Os autores salientam que, as propriedades do agregado graúdo também têm efeito importante nas propriedades do concreto.

Yang e Jiang (2003) verificaram que diminuir o tamanho do agregado graúdo aumenta a resistência do concreto permeável, que, segundo Zhong e Wille (2016), é resultado do aumento na área de ligação entre os agregados. Autores como Yang e Jiang (2003) e Yahia e Kabagire (2014) destacam que agregados graúdos de tamanho único desenvolvem maiores resistências.

A norma 522R-10 (ACI, 2010) destaca que o concreto permeável desenvolve resistência à compressão de até 28 MPa, podendo atingir valores maiores utilizando técnicas especiais de compactação, uso de aditivos químicos e/ou adições.

A adição de uma porcentagem de agregado miúdo, por exemplo, pode trazer ganhos significativos na resistência do concreto permeável, apesar de minorar a taxa de infiltração de água no concreto. Essa adição é limitada e acaba por comprometer a ligação entre os poros, diminuindo o volume de vazios (TENNIS; LEMING; AKERS, 2004; ACI, 2010).

Huang *et al.* (2010), Hölztz (2011), Sanket, Sarita e Taranjeet (2012), Botteon (2017), Kia, Hong e Cheeseman. (2017), Debnath e Sarkar (2020) e Liu *et al.* (2020) optaram por adicionar uma fração de agregado miúdo com o intuito aumentar a resistência do concreto permeável.

Yang e Jiang (2003), Fu *et al.* (2014), Jimma e Rangaraju (2015), Brake, Allahdadi e Adam (2016), Oliveira (2017), Sun *et al.* (2019), Liu *et al.* (2020) e Zhang *et al.* (2020) adicionaram aditivo superplastificante a mistura de concreto permeável a fim de melhorar suas propriedades mecânicas e atingir valores maiores de resistência.

Yang e Jiang (2003), Park *et al.* (2010), Ozbek *et al.* (2013), Nguyen *et al.* (2014), Yahia e Kabagire (2014), Botteon (2017), Sun *et al.* (2019), Chen *et al.* (2019), Chen, Zhao e Bie (2020) e Zhang *et al.* (2020) utilizaram algum tipo especial de compactação ou vibração do concreto no estado fresco para melhorar seu empacotamento dos agregados e obterem melhores resistências.

Castro (2015) diz que, quando executado de forma correta, mesmo com o grande volume de vazios, o concreto permeável consegue atingir valores satisfatórios de resistência, acima de 20,5 MPa para compressão, e 3,5 MPa, para flexão.

Além da redução da resistência, o concreto permeável apresenta outras propriedades diferentes ao concreto convencional. No estado fresco, ele exibe baixa trabalhabilidade, devido sua consistência elevada, e tempo de pega inferior, fatores esses que estão relacionados a porosidade do mesmo, de modo que a utilização de aditivos, que otimizem essas propriedades, torna-se interessante (BATEZINI, 2013).

De maneira geral, a mistura de concreto permeável é mais rígida do que o concreto convencional, sendo seu abatimento em torno de 20 mm e, em alguns casos específicos, 50 mm, apresentando uma baixa trabalhabilidade (TENNIS; LEMING; AKERS, 2004).

Ainda segundo Tennis, Leming e Akers (2004), o peso unitário do concreto permeável é de aproximadamente 70% do concreto convencional, com densidade entre 1600 e 2000 kg/m³. A 522R-10 (ACI, 2010) ressalta que os tamanhos dos poros ficam entre 2 e 8 mm.

Tennis, Leming e Akers (2004) destacam que, no geral, usa-se agregados de tamanhos entre 19 e 1,18 mm, a resistência à compressão fica entre 3,5 e 28 MPa, a resistência à flexão entre 1 e 3,8 MPa, coeficiente de permeabilidade em torno de 3,4 mm/s, mas pode variar de 2 a 12 mm/s.

A norma 522R-10 (ACI, 2010) orienta a utilização de agregados com tamanho entre 19 e 9,5 mm, ressalta que o concreto permeável pode atingir valores de resistência à compressão entre 2,8 e 28 MPa e coeficiente de permeabilidade entre 1,4 e 12,2 mm/s.

A NBR 16416 (ABNT, 2015) determina que, para o emprego do concreto permeável como pavimento, o coeficiente de permeabilidade deve ser maior que 1 mm/s. Além disso, o material deve atender os parâmetros apresentados na Quadro 2.1, segundo sua finalidade.

QUADRO 2.1 – Resistência mecânica e espessura mínima do revestimento permeável segundo seu tipo e solicitação.

| Tipo de revestimento | Tipo de solicitação | Espessura mínima (mm) | Resistência mecânica característica (MPa) | Método de ensaio |
|--|----------------------------|------------------------------|--|-------------------------|
| Peça de concreto (juntas alargadas ou áreas vazadas) | Tráfego de pedestres | 60,0 | $\geq 35,0$ | NBR 9781 |
| | Tráfego leve | 80,0 | | |
| Peça de concreto permeável | Tráfego de pedestres | 60,0 | $\geq 20,0$ | |
| | Tráfego leve | 80,0 | | |
| Placa de concreto permeável | Tráfego de pedestres | 60,0 | $\geq 2,0$ | NBR 15805 |
| | Tráfego leve | 80,0 | | |
| Concreto permeável moldado no local | Tráfego de pedestres | 60,0 | $\geq 1,0$ | NBR 12142 |
| | Tráfego leve | 100,0 | $\geq 2,0$ | |

Fonte: NBR 16416 (ABNT, 2015).

Mesmo que a aplicação do concreto permeável como pavimento apresente benefícios ao meio ambiente, seu emprego é limitado a locais com tráfego leve, devido à natureza de suas propriedades (KEVERN; SCHAEFER; WANG, 2009; ACI, 2010; NEPTUNE; PUTMAN, 2010; LAMB, 2014).

A questão principal a ser resolvida é encontrar o equilíbrio entre resistência mecânica e coeficiente de permeabilidade, de modo que o concreto atenda os valores mínimos estabelecidos em normativas e para que o concreto permeável possa ser aplicado de forma satisfatória.

2.2 COMPOSIÇÃO DO CONCRETO PERMEÁVEL

2.2.1 Cimento Portland

O cimento Portland, tal qual é conhecido no mercado, é um ligante hidráulico resultado da fragmentação do clínquer Portland, obtido pela queima de materiais calcários e argilosos, sulfato de cálcio e outras adições minerais (NBR 16697, ABNT, 2018).

Segundo a Associação Brasileira de Cimento Portland (ABCP, 2022) o cimento é um material em pó, fino, que apresenta propriedades aglutinantes, aglomerantes ou ligantes que endurecem na presença de água. O material é um produto extremamente versátil e pode ser utilizado com diversas finalidades, de acordo com as necessidades de cada obra.

O cimento é o principal componente do concreto, o segundo produto mais consumido no mundo perdendo apenas para a água. O material apresenta uma vasta versatilidade e é usado em todas as áreas da construção (ABCP, 2022).

O material cimentício é o principal aglutinante utilizado no mundo e sua escolha dependerá da finalidade e das características exigidas na produção do concreto. No Brasil, o cimento Portland é dividido segundo seu tipo em cimento Portland comum, composto, de alto-forno, pozolânico, de alta

resistência inicial e o branco. A Quadro 2.2 mostra os limites de composição do material de acordo com a norma brasileira NBR 16697 (ABNT, 2018).

QUADRO 2.2 – Limites de composição do cimento Portland.

| 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) | MATERIAL CARBONÁTICO (FILER CALCÁRIO) | | |
| CP I | - | | | 95 - 100 | 0 - 5 | 0 - 5 | 0 - 5 | - | |
| CP I - S | - | | | 90 - 94 | - | - | - | - | |
| CP II - E | - | | | 51 - 94 | 6 - 34 | - | 0 - 15 | - | |
| CP II - Z | - | 25, 32 E 40 | R S E B C | 71 - 94 | - | 6 - 14 | 0 - 15 | - | |
| CP II - F | - | | | 75 - 89 | - | - | 11 - 25 | ≥ 60 | |
| CP III | - | | | 25 - 65 | 35 - 75 | - | 0 - 10 | - | |
| CP IV | - | | | 45 - 85 | - | 15 - 50 | 0 - 10 | - | |
| CP V | 14 | ARI | | 90-100 | - | - | 0 - 10 | - | |
| CP B | - | 25, 32 E 40 | | 75 - 100 | - | - | 0 - 25 | ≥ 78 | |
| | - | - | | 50 - 74 | - | - | 26 - 50 | ≥ 82 | |

CP I = Cimento Portland comum; CP I - S = Cimento Portland comum com adição; CP II - E = Cimento Portland composto com escória; CP II - Z = Cimento Portland composto com pozolana; CP II - F = Cimento Portland composto com filer; CP III = Cimento Portland composto de alto-forno; CP IV = Cimento Portland Pozolânico; CP V ARI = Cimento Portland de alta resistência inicial; CP B = Cimento Portland branco estrutural e não estrutural; RS = resistente à sulfatação; BC = Baixo calor de hidratação.

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

O cimento Portland comum contém pequenas adições, cerca de 1 a 5%, de pozolana, escória ou carbonato de cálcio. Já o cimento Portland composto possui adições com proporções um pouco mais elevadas (ABCP, 2022).

As adições configuram ao cimento Portland composto propriedades especiais, como por exemplo a adição de pozolana que demonstra uma leve redução na reação álcali-agregado, sendo considerado um cimento menos agressivo, amplamente utilizado em calçadas e passeios.

Para a produção de concreto permeável, Yang e Jiang (2003), Huang *et al.* (2010), Sanket, Sarita e Taranjeet (2012), Maguesvari e Narasimha (2013), Fu *et al.* (2014), Ibrahim *et al.* (2014), Jimma e Rangaraju (2015), Torres, Hu e Ramos (2015), Brake, Allahdadi e Adam (2016), Kia, Hong e Cheeseman. (2017), Chen *et al.* (2019), Sun *et al.* (2019), Yu *et al.* (2019), Chen, Zhao e Bie (2020), Huang *et al.* (2020), Liu *et al.* (2020), Zhang *et al.* (2020), Sherwani *et al.* (2021) e Malami *et al.* (2022) optaram por usar o cimento Portland comum, amplamente empregado na comunidade internacional. Holtz (2011), Lamb (2014) e Botteon (2017) optaram por utilizar o cimento Portland pozolânico.

Tennis, Leming e Akers (2004) e 522R-10 (ACI, 2010), ressaltam que todos os diferentes tipos de cimento Portland podem ser empregados como aglomerante na produção de concreto permeável, desde que atendam as especificações técnicas sobre cimento.

2.2.2 Agregado graúdo

De acordo com a NBR 9935 (ABNT, 2011) agregados são materiais granulares, na maioria das vezes, inertes, que apresentam propriedades e dimensões próprias para a confecção de argamassas e concreto, sendo classificados como agregado miúdo e agregado graúdo.

O agregado graúdo, é o material passante na peneira com abertura de 75 mm e retida na peneira com malha de 4,75 mm. Sua origem se dá por processamento mecânico de rochas (NBR 9935, ABNT, 2011).

A norma 522R-10 (ACI, 2010) destaca que grande parte dos estudos sobre concreto permeável utilizam agregados graúdos com tamanho único ou granulometria entre 19 e 9,5 mm, podendo ser arredondados e triturados, normais e leves, e devem ser evitados materiais escamosos ou alongados. Os agregados devem apresentar boa gradação, resistência, estarem limpos, livres de revestimentos e produtos químicos.

Tennis, Leming e Akers (2004) afirmam que as gradações tipicamente usadas para a produção de concreto permeável estão entre 19 e 4,75 mm ou 9,5, 2,36 mm ou 9,5, 1,18 mm e, em alguns casos, agregados de tamanho único de 25 mm, sendo que agregados maiores fornecem uma superfície mais áspera. Agregados de tamanho máximo de 9,5 mm tem sido vastamente aplicado em estacionamento e calçadas para pedestres. Os autores destacam que os usos de agregados arredondados alcançam valores maiores de resistência, embora agregados angulares também sejam adequados.

Huang *et al.* (2010) utilizaram agregados graúdos de calcário com tamanho único de 12,5 mm, 9,5 mm e 4,75 mm e verificaram que o comportamento do concreto permeável utilizando as três gradações de agregados apresentaram, quanto a porosidade e a permeabilidade, comportamento semelhante, e, quanto a resistência, quanto menor o tamanho do agregado, maior foi o valor de resistência. Zhang *et al.* (2020) também optaram pelo uso de agregados de calcário com tamanho único.

Yang e Jiang (2003) testaram, para a produção de concreto permeável, três diferentes intervalos de tamanhos de agregados graúdos, de 15 a 30 mm, de 10 a 20 mm e de 5 a 10 mm e, assim como Huang *et al.* (2010), verificaram que o tamanho do agregado é inversamente proporcional a resistência do concreto. Agregados menores melhoram a resistência na interface entre o agregado e a pasta de cimento.

2.2.3 Aditivo

Para aumentar a eficiência do concreto permeável, tanto no estado fresco, quanto no estado endurecido, é recorrente a utilização de aditivos químicos, que conferem ao concreto diversas propriedades específicas, melhorando seu desempenho, assim como no concreto convencional (TENNIS; LEMING; AKERS, 2004).

Os aditivos podem ser incorporados a mistura de concreto permeável dentro das proporções indicadas pelo fabricante, cuidadosamente dosadas, e devem atender as normas técnicas vigentes para garantir que o produto final apresente o resultado esperado (522R-10, ACI, 2010).

Dentre os aditivos frequentemente utilizados no concreto permeável estão os aditivos redutores de água, que dependem da relação água/cimento, aditivos retardadores de pega, aditivos aceleradores de pega, aditivos modificadores de viscosidade e aditivos incorporadores de ar (522R-10, ACI 2010).

Os aditivos superplastificantes redutores de água diminuem significativamente a quantidade de água necessária para atingir uma boa trabalhabilidade no concreto permeável, visto que o material apresenta aspecto áspero e seco e, quanto maior for a relação água/cimento, menor é a resistência, portanto, Yang e Jiang (2003) demonstram que a adição do superplastificante redutor de água causou um ganho considerável na resistência do concreto permeável.

Liu *et al.* (2020) usaram aditivo superplastificante redutor de água policarboxilato para melhorar a trabalhabilidade do concreto permeável no estado fresco, obtendo uma redução de água na faixa de 25%. O superplastificante foi usado na proporção de 7,5% da massa do cimento.

Oliveira (2017) utilizou em seu trabalho relação água/cimento de 0,30, em massa, e ADVA CAST 325, como aditivo, na dosagem de 0,45% em relação a massa de cimento e, salienta que os superplastificantes podem ser usados para alterar o tempo de pega do concreto, otimizar a trabalhabilidade e até mesmo alterar a proporção de água/cimento.

Brake, Allahdadi e Adam (2016) adicionaram 0,95% de aditivo superplastificante e 0,26% de modificador de viscosidade, para uma relação a/c de 0,3, e Fu *et al.* (2014) utilizaram 5% de material retardador de pega, para uma relação a/c de 0,25, sendo que todas as relações de emprego dos aditivos

são em relação a massa de cimento. Em todos os casos, os melhores valores de resultados de resistência à compressão, foram aqueles que tinham adotado o aditivo em seu traço.

Jimma e Rangaraju (2015) também utilizaram aditivo superplastificante a base de policarboxilato para a produção de concreto permeável, na dosagem de 0,12, 0,17 e 0,22% de material em relação ao peso do cimento, sendo que a menor dosagem proporcionou à pasta consistência fluida.

Yang e Jiang (2003) testaram o uso de licor de aldeído fenólico como aditivo superplastificante na proporção de 0,8% da massa do aglutinante, concluindo que seu uso produziu pavimentos permeáveis com excelentes propriedades.

Sun *et al.* (2019) e Zhang *et al.* (2020) utilizaram aditivo superplastificante de alto desempenho a base de policarboxilato na proporção fixa de 2,50 kg/m³ de concreto permeável, alterando sua trabalhabilidade e diminuindo a relação a/c, sendo que no trabalho de Zhang foi verificado uma redução de 25% da água.

2.3 TRAÇOS DE CONCRETO PERMEÁVEL

O concreto permeável é um material que apresenta baixo ou nenhum teor de materiais finos (TENNIS; LEMING; AKERS, 2004), sendo composto então, majoritariamente, por agregados graúdos e pasta de cimento. Os autores ainda citam que as relações ideais para esse tipo de concreto estão dentro dos seguintes limites, 0,27 a 0,40, para a relação água/cimento, e de 4:1 a 4,5:1, para a relação agregado/cimento, ambos em massa, e que a adição de uma parcela de agregado miúdo pode ser usada.

A norma americana 522R-10 (ACI, 2010) define, como intervalos satisfatórios, valores para a relação água/cimento, entre a faixa de 0,26 a 0,45, e a relação agregado/cimento, entre de 4:1 a 4,5:1, também em massa.

A Tabela 2.3, resultado de um esforço conjunto entre Associação Nacional de Concreto Misto Pronto (NRMCA) e a Associação de Cimento Portland (PCA), ambas dos EUA, demonstra as proporções de materiais típicas empregadas para a produção de concreto permeável (TENNIS; LEMING; AKERS, 2004; 522R-10, ACI, 2010).

QUADRO 2.3 – Proporção típica de materiais para concreto permeável

| Materiais e relações | Proporções (kg/m³) |
|--|--------------------------------------|
| Materiais cimentícios | 270 a 415 |
| Agregado | 1190 a 1480 |
| Relação água/cimento, em massa | 0,27 a 0,34 |
| Relação agregado/cimento, em massa | 4 a 4,5:1 |
| Agregado miúdo/agregado graúdo, em massa | 0 a 1:1 |

Fonte: 522R-10 (ACI, 2010) e Tennis, Leming e Akers (2004).

O Quadro 2.4 apresenta um compilado de trabalhos sobre o concreto permeável com suas proporções, segundo a revisão bibliográfica realizada.

QUADRO 2.4 – Resumo de traços para concreto permeável de dados da literatura

| Autor | Relação (em massa) | | Tamanho agregado graúdo (mm) | Tipo de cimento | Aditivo/Adições | Resistência à compressão (MPa) |
|--------------------------------|-------------------------|---------------------------------|--|-----------------|--|--------------------------------|
| | a/c | ag/cim | | | | |
| Tennis, Leming e Akers (2004) | 0,27 a 0,40 | 4:1 a 5:1 | Até 25 9,5 - Mais utilizado | CP | Indica o uso | 3,5 a 28 |
| 522R (ACI, 2010) | 0,26 a 0,45 | 4:1 a 4,5:1 | 9,5 a 19 | - | Indica o uso | 2,8 a 28 |
| Huang <i>et al.</i> (2010) | 0,35 | 4,5:1 | 12,5, 9,5 e 4,75 | CP | Porção sólida do látex foi utilizada para substituir 10% de cimento | 15 |
| Höltz (2011) | 0,26; 0,30; 0,35 e 0,45 | 4:1 a 9:1 | 9,5 a 19 | CP V ARI | - | 8,1 |
| Magnusvari e Narasimha (2013) | 0,34 | 4,75:1 | 16 a 19; 12,5 a 16; 9 a 12,5; e 4,75 a 9 | CPc | - | 26,90 |
| Fu <i>et al.</i> (2014) | 0,25; 0,35 e 0,45 | 4,1:1 a 6,75:1 | 12,5, 19, 25 e 37,5 | CPc | SP retardador de pega 5% da massa de cimento | 28,73 |
| Lamb (2014) | 0,25 | 3:1, 3,5:1 e 4:1 | 9,5 | CP V ARI | - | 21,09 |
| Torres, Hu e Ramos (2015) | 0,33 | 2,47:1 a 6,52:1 | 6,35 e 9,5 | CP tipo I e II | - | 18,60 |
| Brake, Allahdadi e Adam (2016) | 0,30 e 0,27 | 3,8:1 a 7:1 | 9 | CPc | 0,26% de agente modificador de viscosidade e 0,95% de SP, a base de polycarboxilato, em relação a massa de cimento | 34,90 |
| Botteon (2017) | 0,30 e 0,35 | 4:1 e 4,44:1 | 12,5 | CP V ARI | Uso de sílica ativa e outros aditivos para pesquisas futuras | 23,21 |
| Kia, Hong e Cheeseman. (2017) | 0,20 a 0,50 | 2:1 a 12:1 | 9,5 a 19 | CPc | Verificou o uso de sílica ativa, escória, cinza volante e SP. | 1 a 28 |
| Yu <i>et al.</i> (2019) | 0,31 | 4,5:1 | Até 15 | CPc | - | 32 |
| Debnath e Sarkar (2020) | 0,28, 0,3, 0,32 e 0,35 | 2,54:1, 2,62:1, 2,71:1 e 2,84:1 | 2,36 a 19 | CP ordinário | Plastificante (BASF Master Rheobuild 1125) na proporção de 0,8% sobre a massa de cimento | 42,31 |
| Liu <i>et al.</i> (2020) | 0,22 | 3,7:1 | 5 a 10 e 10 a 15 | CPc PO 52,5 | 1,7 %; cinza volante 10% e sílica ativa 7,5 % (em relação a massa de cimento) e fibra de basalto em um teor de 0,2%, em volume | 45,24 |
| Zhang <i>et al.</i> (2020) | 0,25 a 0,50 | 2,5:1 a 4,5:1 | 3,75; 7,5; 13 | CPc | SP à base de polycarboxilato na proporção de 2,50 kg/m ³ de concreto, com vibração mecânica | 5 a 30 |
| Sherwani <i>et al.</i> (2021) | 0,27 e 0,32 | 2,42:1 a 5,76:1 | 8 a 12,5 | CPc PO 42,5 | Cinza volante 0, 25, 50 e 100%, em relação a massa do cimento | 22,90 |

a/c = Relação água/cimento; ag/cim = relação cimento/agregado; ag.m/ag.g = relação agregado miúdo e agregado graúdo; CP = Cimento Portland; c = Cimento Portland Comum; SP = Superplastificante;

Fonte: o autor

O Quadro 2.4 traz em seu escopo um compilado de trabalhos que estudaram o concreto permeável, com o objetivo de analisar e comparar as pesquisas entre si e com a norma 522R (ACI, 2010), sendo os resultados para resistência à compressão o foco principal do resumo. Optou-se por destacar, segundo cada autor, as relações entre os traços, os tipos materiais que compõem o concreto permeável e suas proporções (em massa), além da influência desses fatores na resistência.

Observando o Quadro 2.4, pode-se notar que os valores da proporção água/cimento ficou entre 0,20 e 0,50, a relação agregado/cimento entre 2:1 e 12:1, sendo que a grande maioria ficou por volta de 4,5:1 e com resistência à compressão entre 1 e 45,24 MPa, sendo que a maioria optou por utilizar cimento Portland comum.

Sun *et al.* (2019) e Zhang *et al.* (2020) optaram por testar as seguintes relações água/cimento: 0,25, 0,30, 0,35, 0,40, 0,45 e 0,50. As relações agregado/cimento: 2,5:1, 3:1, 3,5:1, 4:1 e 4,5:1, sem agregado miúdo e com adição de aditivo superplastificante.

Autores como Huang *et al.* (2010), Holtz (2011), Magesvari e Narasimha (2013), Botteon (2017), Kia, Hong e Cheeseman. (2017), Debnath e Sarkar (2020) e Liu *et al.* (2020) obtiveram resultados satisfatórios para resistência quando adicionaram um teor de agregados miúdos.

3. APRENDIZAGEM DE MÁQUINA

A aprendizagem de máquina (AM) é um ramo da inteligência artificial que utiliza sistemas computacionais para aprender determinado padrão de um conjunto de dados, de modo que seu comportamento possa ser previsto posteriormente. Sem precisar ser programado de forma explícita, modelos de AM relacionam, estatisticamente, dados de entrada e saída, aprendendo sobre os parâmetros utilizados, com o intuito de reproduzir seu comportamento (SAMUEL, 1959).

Como uma alternativa econômica e rápida, a aprendizagem de máquina ganha destaque na estimativa de dados experimentais, além de gerar soluções para problemas matemáticos de difícil solução (SHARIATI *et al.*, 2020).

De um modo geral, a AM pode ser dividida em dois tipos principais: aprendizagem descritiva ou não supervisionada e aprendizagem preditiva ou supervisionada (MURPHY, 2012). Segundo o autor, na aprendizagem não supervisionada, recebe-se apenas os dados referentes a entrada, para a busca de padrões relevantes, sem orientação sobre o que deve ser considerado, enquanto na aprendizagem supervisionada, modelo mais utilizado na prática, recebe-se dados de entrada e saída, tornando a identificação dos padrões mais simples.

Para Morgan e Jacobs (2020) na aprendizagem descritiva, o treinamento dos dados ocorre sem o direcionamento humano, cabendo ao mesmo encontrar relações por si só. Já na aprendizagem preditiva, utiliza-se informações específicas, relacionando a correspondência entre um valor de x e um valor de y , necessitando de ação humana para sua realização.

Na AM os problemas podem ser definidos como de classificação ou de regressão a depender da resposta y . Se y for um valor categórico, é considerado de classificação, ou se o y for um escalar de valor real, problema de regressão (MURPHY, 2012).

A aprendizagem de máquina tem grande potencial, especialmente em áreas críticas, como alta tecnologia e saúde, que comprometem bilhões de dólares para o seu desenvolvimento e disseminação (MORGAN; JACOBS, 2020). É uma metodologia que encontra tendências e padrões em determinadas observações fazendo previsões e classificações.

Aplicações de técnicas de AM tomaram maiores proporções nos últimos 20 anos, vencendo desafios que os seres humanos, muito provavelmente, levariam décadas para solucionar. Kumar *et al.* (2022) destacam que os modelos de aprendizagem de máquina são empregados em diversas áreas da engenharia civil, por exemplo, para previsão, otimização e categorização.

Modelos de aprendizagem de máquina buscam basicamente construir relações entre dados de entrada e dados de saída, por meio de técnicas estatísticas, capacitando o computador através do treinamento de um conjunto de dados (SAMUEL, 1959).

Modelos que utilizam inteligência artificial são promissores em abordagens preditivas de materiais heterogêneos (GHABOUSSI *et al.*, 1991; CHAABENE; FLAH; NEHDI, 2020; FAROOQ *et*

al., 2021a; FAROOQ *et al.*, 2021b), resistência à compressão de concretos (YEH, 1998, FAROOQ *et al.*, 2020, SALIMBAHRAMI; SHAKERI, 2021) e de propriedades do concreto permeável.


Além da previsão, como menciona Kamar *et al.* (2022), a aprendizagem de máquina permite otimização de resultados (GHOLAMPOUR; GANDOMI; OZBAKKALOGLU, 2017; DUAN *et al.*, 2020; HAN *et al.*, 2020). Por meio do ajuste de seus respectivos hiperparâmetros, os modelos podem alcançar resultados melhores ainda.

Graças a expansão dos modelos de aprendizagem de máquina, seu emprego vem sendo difundido, tornando sua implementação ao longo do tempo mais fácil e acessível (JHA *et al.*, 2020).

3.1 MODELOS DE APRENDIZAGEM DE MÁQUINA

A aprendizagem de máquina oferece uma grande variabilidade de modelos que podem ser ajustados para solucionar diversos problemas a partir de um conjunto de dados. Kuhn e Johnson (2013), para prever dados de solubilidade de compostos químicos, compararam o comportamento de diferentes modelos, calculados por meio da validação cruzada e conjunto de teste, como pode ser visto na Figura 3.1.

FIGURA 3.1 – Gráfico dos modelos testados e os valores de coeficiente de determinação R^2 (R-Squared) por validação cruzada de 10 vezes e o conjunto de teste, para a predição da solubilidade.



SVMp = Máquinas de vetores de suporte com Kernel polinomial; SVMr = Máquinas de vetores de suporte com Kernel de função de base radial; MARS = Modelos de splines de regressão adaptativo multivariada; PLS = Mínimos quadrados parciais; KNN = K-vizinhos mais próximos.

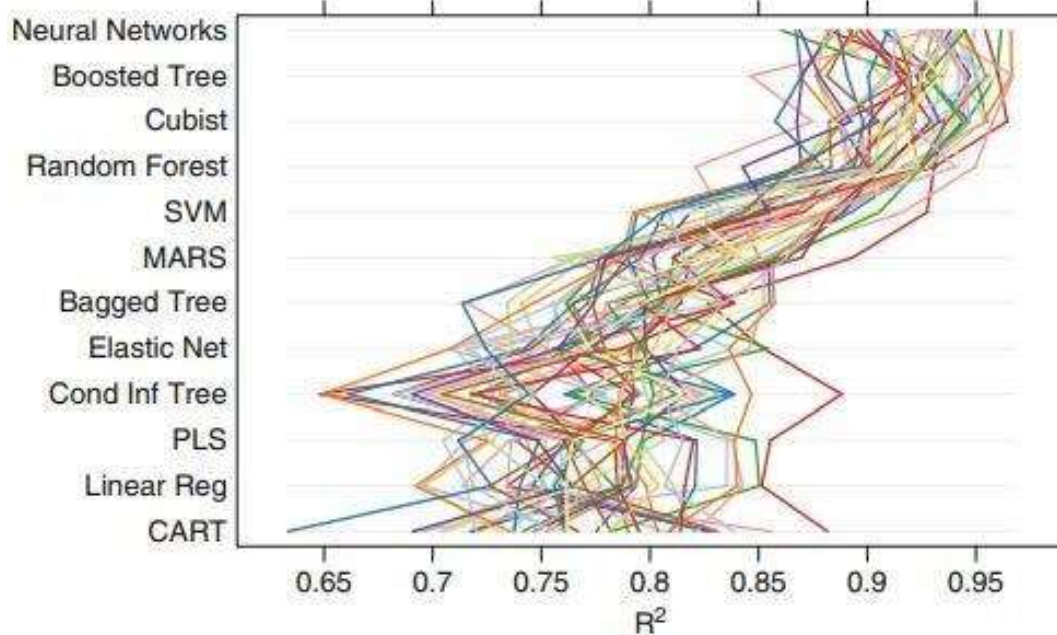
Fonte: Kuhn e Johnson (2013).

A Figura 3.1 verifica e destaca o grupo de modelos que apresentou alto desempenho, sendo eles as máquinas de vetores de suporte (SVM) com base polinomial e radial, árvores reforçadas, florestas

aleatórias e o *cubist*, posteriormente alguns modelos que apresentaram comportamento mediano e por último o modelo k-vizinhos mais próximos (KNN), com pior desempenho.

Para um estudo específico de resistência à compressão de misturas de concreto, Kuhn e Johnson (2013), compararam o desempenho de diversos modelos de aprendizagem de máquina, como mostra a Figura 3.2.

FIGURA 3.2 – Gráficos de coordenadas paralelas para R^2 com validação cruzada em diferentes modelos. Cada linha representa os resultados para um conjunto comum de validação cruzada.



SVM = Máquinas de vetores de suporte; MARS = Modelos de splines de regressão adaptativo multivariada; PLS = Mínimos quadrados parciais; CART = árvore de classificação e regressão.

Fonte: Kuhn e Johnson (2013).

Analisando a Figura 3.2 nota-se que os modelos que apresentaram melhor desempenho são os mesmos do estudo apresentado na Figura 3.1, *neural networks, boosted tree, cubist, random forest e SVM*, mostrando concordância entre os mesmos.


3.1.1 K-Neighbor Regressor (KNN)

O K-Neighbor Regressor (KNN) ou k-vizinhos mais próximos (BENEDETTI, 1977; STONE 1977) é um modelo que busca analisar um grupo de dados de treinamento vizinhos a um determinado ponto para prever seu valor (ALTMAN, 1992), ou seja, para estimar ou classificar um ponto, o algoritmo KNN avalia os “k” vizinhos mais próximos a ele. Este modelo soluciona problemas de classificação e regressão.

Mahesh (2020) considera que o KNN é, entre os algoritmos de aprendizagem de máquina, o que apresenta mais simplicidade e com maior aplicação para problemas de classificação, por ser considerado um modelo de fácil entendimento e com um design flexível. A Figura 3.3 ilustra o funcionamento do

modelo KNN, para um k igual a 4, ou seja, o ponto de estudo dependerá dos 4 pontos mais próximos a ele. Os pontos 1, 2 e 3 fazem parte da “classe C” e o ponto 4 da “classe A”, logo, o novo ponto será classificado como “classe C”, pois a maioria dos pontos vizinhos a ele pertencem a esta classe. A determinação ocorre por meio de uma votação majoritária.

FIGURA 3.3 – Uma ilustração de K-vizinhos mais próximos (KNN).



Fonte: Duan *et al.* (2021).

O KNN é uma metodologia que se baseia na distância entre os pontos estudados, sendo que os mais próximos possuem maior peso do que os que estão distantes. O cálculo da distância pode ser verificado pela equação euclidiana (Equação 3.1), apesar de outras métricas também poderem ser utilizadas.

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

Onde:

x_i e x_j são duas instâncias representadas por vetores no espaço \mathbb{R}^d ;

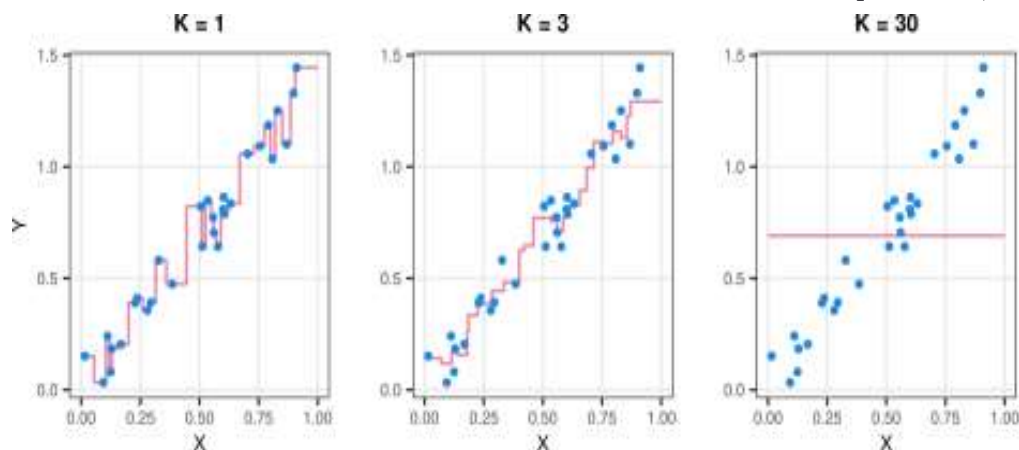
x_i^l e x_j^l são elementos desses vetores, que correspondem aos valores da coordenada l

(atributos).

Murphy (2012) avalia que, embora o KNN seja simples, só funcionará bem se considerar uma boa medida de distância e se obtiver dados de treinamento rotulados o suficiente. Além disso, ele não funciona de maneira satisfatória com altas entradas dimensionais, por isso a importância de se estabelecer bons parâmetros.

Izbicki e Santos (2020) ressaltam a importância da escolha do k , *turning parameter* ou parâmetro de ajuste, uma vez que um elevado valor de k resulta em um modelo simples com um viés elevado e baixa variância, enquanto para um baixo valor de k , ocasiona o inverso, estima com alta variância e baixo viés. A Figura 3.4 demonstra como o valor de k interfere no resultado do modelo.

FIGURA 3.4 – Influência da escolha de k no estimador de k -vizinhos mais próximos (KNN).



Fonte: Izbicki e Santos (2020).

3.1.2 Bayesian Regularization Neural Network (BRNN)

O modelo Bayesian Regularization Neural Network (BRNN) ou rede neural de regularização bayesiana, foi proposto originalmente por MacKay em 1991 (MACKAY, 1991), integrando as propriedades de aprendizagem das redes neurais artificiais e dados prévios estatísticos bayesianos (BURDEN; WINKLER, 2008).

O objetivo principal do modelo BRNN é a diminuição dos possíveis efeitos do *overfitting*, sobreajustes, adicionando um termo extra, chamado de regulador, à soma dos erros quadrados da rede neural, com o intuito de mitigar tal efeito (LAHMIRI; BEKIROS, 2020). A adição desse termo oferece ao modelo um maior recurso para generalização.

Segundo Kurnaz e Kaya (2018) o BRNN possui como vantagem a indicação de quantos pesos da rede serão de fato utilizados, mostrando o tamanho ideal da rede. Nas redes neurais artificiais convencionais, um maior ou menor número de neurônios, pode levar ao erro do ajuste, de forma excessiva ou insuficiente.

As redes neurais artificiais (ANN) convencionais possuem três camadas sendo elas: entrada, oculta e saída, onde pesos são conferidos a junção de dois neurônios nessas camadas, enquanto a retroprogramação de erros é empregada de modo a ajustar esses pesos durante o processo de aprendizagem (ALTHOFF; FILGUEIRAS; RODRIGUES 2020). A diferença entre o ANN e o BRNN é que no BRNN é adicionado um parâmetro de penalidade, chamado regularização, controlando os pesos de modo a penalizar altos valores para o comprimento (HASSAN; KHAN, 2022).

Burden e Winkler (2008) afirmam que BRNN apresentam maior robustez quando comparadas com as redes de retroprogramação padrão e podem mitigar ou até eliminar a validação cruzada demorada.

3.1.3 Boosted Tree (*Blackboost*)

Boosted tree ou árvore aprimorada, lida com erros. Árvores de decisão são criadas a partir dos erros das árvores criadas anteriormente, sendo um tipo de aprendizagem sequencial. O *boosting* trabalha como fortalecedor de árvores a fim de minimizar seu erro. A função *blackboost* implementa o *boosting* (BUHLMANN; HOTHORN, 2007).

Os modelos de *boosting* foram desenvolvidos inicialmente para problemas de classificação. O algoritmo surgiu com o algoritmo *AdaBoost*, no início dos anos 1990 (SCHAPIRE, 1990; FREUND, 1995; SCHAPIRE, 1999). O modelo é considerado simples e altamente adaptável, buscando uma forma de minimizar a função de perda (KUHN; JOHNSON, 2013).

As árvores possuem flexibilidade, podem ser facilmente ajustadas, e adicionadas umas às outras, além de serem geradas rapidamente. A *Boosted tree* pode ainda ser ajustada, para o modelo *blackboost*, pelas árvores (*mstop*) e pela profundidade máxima da árvore (*maxdepth*) (KUHN, 2017).

Kuhn e Johnson (2013) destacam que esse modelo se assemelha as florestas aleatórias, se diferenciando apenas pela forma que os conjuntos são construídos. No *boosted tree* as árvores dependem das anteriores, possuem profundidade mínima e não contribuem de forma igual para o resultado final. Este tipo de modelo pode ser ajustado de forma excessiva.

3.1.4 Support Vector Machines (*svmRadial*)

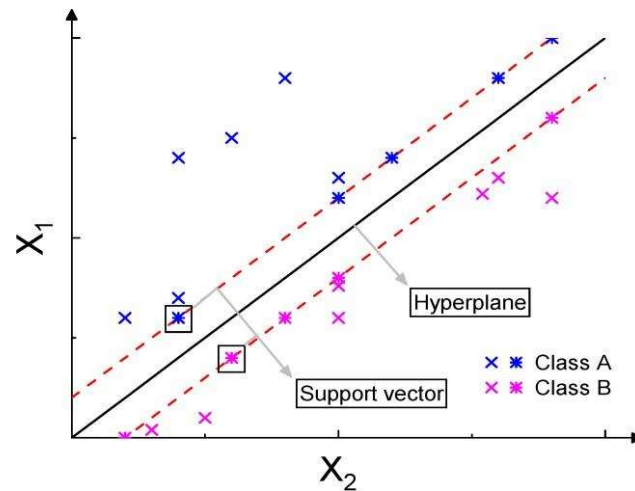
A rede de vetores de suporte é um modelo de aprendizagem de máquina para problemas de classificação de dois grupos. A máquina de vetor suporte (SVM) é uma espécie de algoritmo, criado por Vapnik e Cortes em meados dos anos 1990, que possui como base a minoração do risco estrutural, buscando aprender o limite entre dois níveis, mapeando os dados de entrada para uma área de alta dimensão (TONG; KOLLER, 2001).

Inicialmente, o modelo SVM foi criado para solucionar problemas de classificação, até que seu uso foi ampliado para problemas de regressão (VAPNIK, 1995). O algoritmo estima a variável de saída segundo as variáveis de entrada, visando que, pontos de um mesmo conjunto, permaneçam do mesmo lado do hiperplano.

Os dados de entrada do modelo são mapeados de maneira não linear para uma área de recursos de dimensões altíssimas e, dentro dessa área de propriedades específicas, é construída uma superfície de decisão linear com grande capacidade de generalização (CORTES; VAPNIK, 1995).

SVM é um tipo de aprendizagem que funciona da seguinte forma: os dados de treinamento são recebidos, sendo eles vetores em algum espaço, além de ser-lhes conferido seus rótulos, para sua posterior classificação. Os SVMs são espaços vetoriais, que dividem os dados de treinamento por uma margem máxima, sendo que os campos de treinamento que estão mais próximos do hiperplano, recebem a nomenclatura de vetores de suporte (TONG; KOLLER, 2001). A Figura 3.5 demonstra uma SVM.

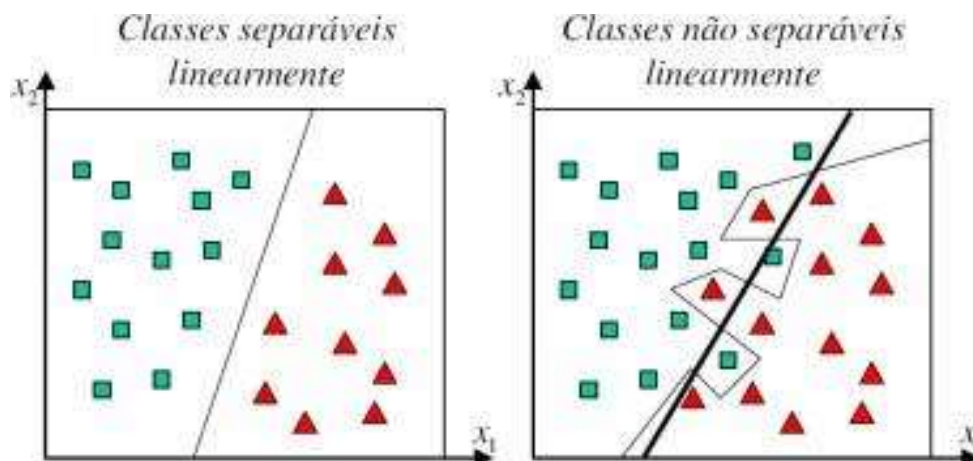
FIGURA 3.5 – Uma ilustração da máquina de vetores de suporte (SVM).



Fonte: Duan *et al.* (2021).


Para casos que não apresentam linearidade, a função de kernel com base radial tem se mostrado eficaz. A função não linear RBF (*Radial Basis Function*), de acordo com Brown, Lewis e Gunn (2000), é a mais adequada na caracterização de classes em hiperplano não lineares. A diferença entre modelos lineares e não lineares pode ser visto na Figura 3.6. A Figura 3.7 compara a função não linear polinomial com a função não linear RBF.

FIGURA 3.6 – Separação das classes por um hiperplano.



Fonte: Pereira *et al.* (2011).

FIGURA 3.7 – Algoritmo SVM Kernel Polinomial e Radial.



Fonte: James *et al.* (2017).

O SVM não estima a probabilidade, os valores de saída nesse modelo apontam as classes estimadas de novas observações. No caso de haverem mais de um hiperplano, o algoritmo buscará o que apresenta a maior margem, ou seja, o que estiver mais distante entre os pontos observados (IZBICKI; SANTOS, 2020). Neste modelo, busca-se determinar uma linha ótima de classificação, um hiperplano separador ótimo, classificando os dados corretamente e maximizando suas margens.

A Equação matemática 3.2 corresponde ao *svmRadial* para classificação de funções não lineares.

$$K(x_i, x_j) = \exp(-\gamma \sum_{i=1}^p (x_i - x_j)^2) \quad (3.2)$$

Onde:

(x_i, x_j) vetores; x_i, x_j

p Tamanho dos vetores;

O emprego de hiperparâmetros conferem ao modelo ajustes que otimizam seus resultados. Para o *svmRadial* o parâmetro de ajuste C (custo), encontrado tanto no SVM linear quanto no não-linear, é responsável por controlar a tolerância dos erros do algoritmo, de modo a penalizá-lo quando falhar, ou seja, cada erro possui um custo para o modelo (ADEWUMI *et al.*, 2016).

Na função de Kernel, *svmRadial*, o hiperparâmetro sigma também é empregado, sendo ele um peso introduzido para a distância das amostras, conferindo maior ou menor relevância aos dados mais próximos ou mais distantes da linha de decisão (KUHN, 2019).

O C controla a compensação dos erros cometidos no treinamento, sendo o parâmetro de margem que determina um ponto médio, de equilíbrio, entre a maximização da margem e a minimização do erro de classificação e o σ controla o raio de kernel RBF.

Os benefícios da utilização da função de base radial do kernel são sua boa generalização, forte tolerância a ruídos de entrada, os modelos respondem bem a conjuntos de dados sem treinamento (YU *et al.*, 2011), boa capacidade de estimativa e rápida aprendizagem.

Zheng *et al.* (2019) e Ahmed *et al.* (2021) utilizaram o modelo SVM com base radial para prever propriedades do concreto. Zheng obteve uma precisão acima de 98% no seu estudo o nível de umidade do concreto. Ahmed utilizou o modelo para prever a resistência à compressão do concreto permeável, obtendo R^2 para os dados de teste de 0,7626.

3.1.5 Random Forest

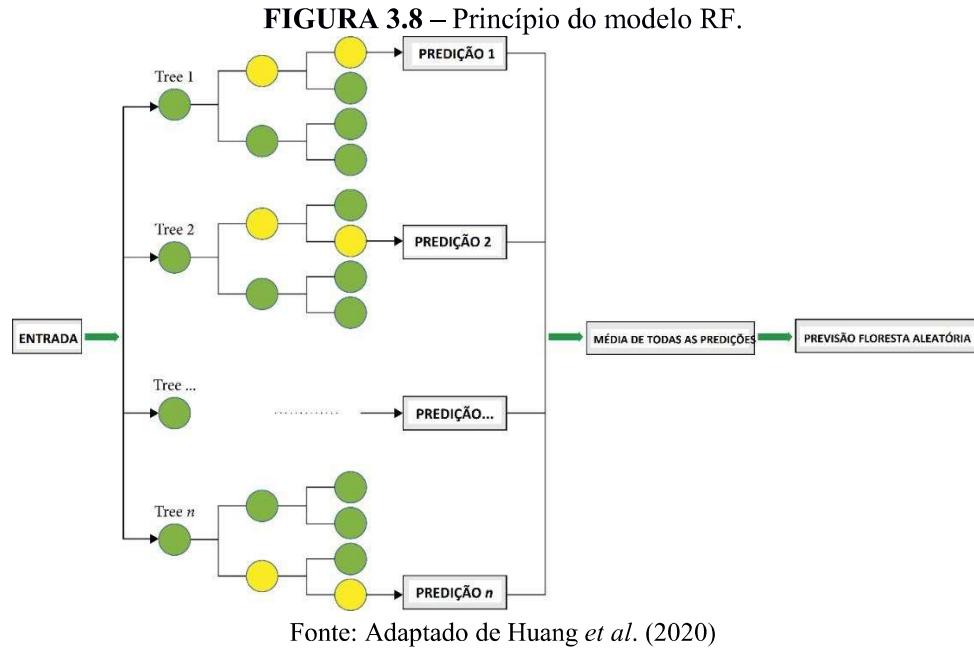
O modelo conhecido como *Random Forest* (RF - florestas aleatórias) pode ser definido como sendo uma combinação entre diversas árvores de decisão, ou regressão, criadas de maneira aleatória para prever dados baseado em valores de entrada, sendo que os valores de saída correspondem a média dos valores previstos nas árvores individuais (DEGTYAREV, 2022).

A princípio separa-se uma amostra do conjunto total para treinamento dos dados, gerando uma árvore de decisão. Em seguida, propriedades são escolhidas de modo aleatório e distribuídas pelos nós da árvore de decisão, sendo esse procedimento repetido por n vezes, até que a floresta aleatória possa ser gerada (DUAN *et al.*, 2021).

O RF verifica a importância das variáveis no resultado e utiliza a média entre as árvores de decisão para prevêê-los. O algoritmo permite, com o aumento do número de árvores, que ocorra uma “votação” entre elas para definir qual categoria é predominante.

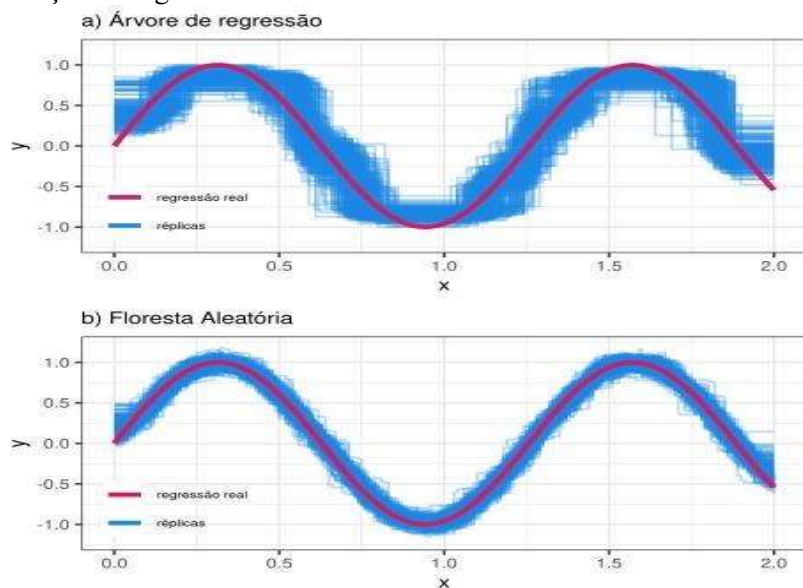
Breiman (2001) define RF da seguinte forma: “é um classificador que consiste em uma coleção de classificadores estruturados em árvore $\{h(x, \Theta_k), k = 1, \dots\}$ onde os (Θ_k) são vetores aleatórios distribuídos identicamente independentes e cada árvore lança um voto unitário para a classe mais popular na entrada x ”.

A Figura 3.8 demonstra a estrutura principal do modelo, onde são selecionados nos dados de entrada, amostras para treinamento e posterior previsão de resultados, de forma aleatória, para que, utilizando a média entre as previsões, o modelo de previsão de floresta aleatória possa ser utilizado.



A união de várias árvores de decisão minimiza a variância, pois ao invés de fazer a estimativa baseado em apenas uma árvore, faz-se a média entre diversas estimativas, obtendo um maior poder de predição. A Figura 3.9 descreve e compara o comportamento de árvores e florestas, após ajustes, deixando nítido que as árvores apresentam variabilidade mais alta que as florestas, demonstrando que elas possuem menor rendimento (IZBICKI; SANTOS, 2020).

FIGURA 3.9 – Ajustes de árvore de regressão e florestas aleatórias para diferentes conjuntos de dados vindo da mesma função de regressão.



Fonte: Izbicki e Santos (2020).

3.1.6 *Cubist*

O algoritmo *cubist*, criado por Quinlan no início dos anos 1990, é uma técnica não paramétrica de aprendizagem de máquina, que gera árvores de modelos preditivos baseado em regras (QUINLAN, 1992; 1993; 1996). O *cubist* foi fundamentado em uma extensão do algoritmo de árvore M5 de Quinlan e é um modelo de regressão orientada.

O *cubist* é uma técnica explícita, de fácil compreensão. Nesse modelo ocorre a subdivisão dos dados por meio de regras, organizadas de maneira hierárquica, que estão associadas as variáveis preditoras, ajustando cada subconjunto por um modelo de regressão linear, de modo a minimizar erros.

Kuhn *et al.* (2022) detalham que no modelo *cubist*, a princípio, cria-se uma estrutura de árvore que é reduzida a cada regra, sendo um modelo de regressão ajustado para cada regra, baseando-se no subconjunto de dados definidos pelas regras. O grupo de regras é podado ou combinado, e as variáveis candidatas aos modelos de regressão linear serão as preditoras que foram usadas nas partes que foram podadas.

Um modelo de regressão multivariado é representado por cada folha da árvore, ou seja, uma regra, relacionado a uma ou mais condições ou limites do subconjunto de variáveis explicativas empregadas na calibração da regra (HOUBORG; MCCABE, 2018). A previsão no *cubist* pode ser otimizada criando-se vários modelos baseados em regras, chamados comitês.

Nguyen *et al.* (2019) salientam que o algoritmo *cubist* é basicamente dividido em quatro etapas, sendo elas a ramificação dos dados para a criação completa da árvore, o desenvolvimento de um modelo de regressão para cada nó, para posterior poda e previsão, a poda da árvore para erros e alinhamento da árvore para sua uniformização ocasionada nas podas ou divisões.

Em cada parte da “árvore”, seleciona-se um modelo, sendo o valor final predito uma combinação entre o modelo “pai” e o modelo “filho”, que refletem desde o nó inicial até o nó final de toda a “árvore” (QUINLAN, 1992). No *cubist*, como mostra a Equação 3.3, os modelos ainda são combinados usando uma combinação linear de dois modelos:

$$\hat{y}_{par} = a \hat{y}_{(k)} + (1 - a)\hat{y}_{(p)} \quad (3.3)$$

Onde:

\hat{y}_{par} Combinação;

a Suavização;

$\hat{y}_{(k)}$ Previsão do modelo atual;

$\hat{y}_{(p)}$ Previsão do modelo pai.

O modelo *cubist* permite ser configurado de modo composto combinando aprendizagem baseado em regras e instâncias, com o intuito de otimizar a precisão de suas previsões (QUINLAN, 1993).

Conhecido como uma ampliação do M5, o *cubist* transforma a técnica de suavização da resposta predita incluindo dois parâmetros: os *committees* (comitês) e *neighbors* (vizinhos). O conceito de comitês análogo ao de “boosting”, desenvolve uma série de árvores de maneira sequencial com pesos ajustados, sendo a previsão final dada pela média simples das previsões de todos os membros do comitê. Os vizinhos são os valores mais próximos, ou mais semelhantes, da observação, da qual se deseja prever, no conjunto de treinamento. Ambos podem ser estimados através da validação cruzada k-fold (KUHN; JOHNSON, 2013).

Os comitês são representados pela sequência de modelos, onde cada resultado é afetado pelo resultado anterior, de modo que através da aplicação do algoritmo, os resultados sucessores possam ser corrigidos e ajustados pelo próximo comitê (SANTOS, 2018). Ainda segundo o autor, para complementar e otimizar o valor predito, pode-se acrescentar, como parâmetro, k valores de vizinhos mais semelhantes.

A principal vantagem relacionada ao modelo *cubist* é a incorporação de diversos comitês no treinamento e reforço, de modo a deixar os pesos mais equilibrados, observando as instâncias similares.

A utilização do *cubist* se mostrou positiva em diversas áreas como mostram os trabalhos de Houborg e McCabe (2018), Lacoste *et al.* (2014), Zhou *et al.* (2019) e Nguyen *et al.*, 2019, que obtiveram valores de coeficiente de determinação igual a 0,96, 0,8, 0,9697 e 0,989, respectivamente.

3.1.7 Relevance Vector Machines (rvmRadial)

A máquina de vetores de relevância ou RVM, desenvolvida por Tipping nos anos 2000, é um modelo Bayesiano esparsos especializado, baseado em kernel, similar ao método SVM (TIPPING, 2006). O modelo combina a esparsidade e a precisão preditiva, para treinar modelos lineares generalizados.

Tipping (2000) demonstra que, para o modelo RVM, é adicionado uma priorização entre os pesos governados por um conjunto de hiperparâmetros, referindo-se um em cada peso, sendo essa a principal característica do modelo, onde seus valores mais prováveis são estimados de maneira iterativa segundo os dados. Além do mais, o autor salienta que, as distribuições posteriores em muitos pesos estão próximas de zero e eles não estão associados a exemplos próximos ao limite de decisão, e sim, a protótipos de classes, sendo esses exemplos de vetores denominados de “relevância”.

O RVM vê os dados como um sistema e pressupõe que eles contenham informações sobre a variável resposta (KHALIL *et al.*, 2005). O modelo busca simplificar sistemas complexos, o estruturando, e possui alta capacidade de generalização, mas não identifica a importância das variáveis separadamente.

Quando comparado ao SVM, o RVM, no geral, apresenta menores funções de kernel, o que o torna mais atrativo. O modelo pode ser generalizado e possui custo computacional baixo.

3.2 APRENDIZAGEM DE MÁQUINA NA PREDIÇÃO DE PROPRIEDADES DE CONCRETO

Devido a limitação na compreensão das complexas relações entre as misturas de concreto e suas propriedades faz-se necessário o desenvolvimento de mecanismos preditivos que as correlacione. A aprendizagem de máquina fornece uma alternativa a abordagens tradicionais, trazendo maior confiabilidade na predição de dados.

Nos últimos anos autores como Shirgir, Mamdoohi e Hassani (2015), Adewumi *et al.* (2016), Sun *et al.* (2019), Chen, Zhao e Bie (2020), Huang *et al.* (2020), Pareek e Hong (2020) Zhang *et al.* (2020), Ahmed *et al.* (2021), Le *et al.* (2022) e Malami *et al.* (2022) empregaram diferentes modelos de aprendizagem de máquina para prever importantes propriedades do concreto permeável, obtendo resultados satisfatórios, como pode ser visto a seguir.

Zhang *et al.* (2020) destacam que, devido a não linearidade entre as propriedades do concreto permeável, como por exemplo a sua resistência à compressão ou seu coeficiente de permeabilidade, e de seus componentes, os modelos matemáticos tradicionais não conseguem modelar suas relações, necessitando de uma outra alternativa. Para tanto, os autores propõem o emprego de inteligência artificial como uma ferramenta de solução para esse problema.

O modelo híbrido de aprendizagem de máquina adotado por Zhang *et al.* (2020) foi o método de regressão vetorial de suporte de mínimos quadrados com várias saídas (MOLSSVR), ajustado pelo algoritmo de busca de antenas de besouros (BAS) modificado, que além de tudo, melhora a precisão da previsão, utilizando a relação entre os dados de saída, resistência à compressão e coeficiente de permeabilidade. Os autores obtiveram para os dados de resistência à compressão, R^2 igual a 0,9991 para treino e 0,9911 para teste, e para os dados de permeabilidade, R^2 igual a 0,9878 para dados de treino e 0,9442 para teste.

Sun *et al.* (2019) utilizaram para prever a permeabilidade e a resistência à compressão do concreto permeável, um modelo de aprendizagem de máquina, uma, encontrando um baixo RMSE, 0,147 mm/s para treino e 0,218 mm/s para teste, em relação a permeabilidade, e 0,353 MPa para treino e 0,577 MPa para teste, em relação a resistência à compressão, e um alto coeficiente de determinação R^2 , sendo para resistência à compressão, 0,9997 para treino e 0,996 para teste, e para permeabilidade, 0,9892 para treino e 0,9816 para teste, indicando uma capacidade preditiva alta.

Huang *et al.* (2020) propuseram um método que combina os algoritmos de pesquisa de antenas de besouro (BAS) e floresta aleatória (RF) para prever a permeabilidade do concreto permeável, concluindo que a eficiência da utilização de inteligência artificial na predição de propriedades do

concreto permeável, encontrando coeficiente de determinação de 0,9258 para dados de treino e 0,9208 para teste.

Malami *et al.* (2022) aplicaram modelos de inteligência artificial para a previsão da resistência à flexão de concreto permeável, testando os algoritmos máquinas de vetor de suporte (SVM), redes neurais artificiais (ANN) e sistema de inferência neuro-fuzzy adaptativo (ANFIS), obtendo resultados satisfatórios na predição, sendo o último o que melhor se adaptou com RMSE igual a 0,0044 MPa, provando a precisão do modelo.

Le *et al.* (2022) utilizaram a aprendizagem de máquina para avaliar a resistência à compressão e a porosidade efetiva do concreto permeável, empregando os métodos: aumento de gradiente extremo (XGB), regressão de floresta aleatória e máquinas de vetor de suporte (SVM). O modelo XGB superou os demais, com R^2 de até 0,99 para resistência à compressão e 0,97 para porosidade efetiva, revelando a eficácia da precisão da pesquisa.

Ahmed *et al.* (2021) empregaram o modelo de regressão vetorial de suporte (SVR) para prever a resistência à flexão do concreto permeável. Os autores optaram pelo uso da máquina de vetor de suporte (SVM) com parâmetros da função de base radial devido a sua boa generalização, por ser um algoritmo de aprendizagem rápida e boa capacidade de estimativa, entretanto, chegaram à conclusão de que o modelo utilizado é menos eficaz quando são submetidos a uma ampla gama de dados.

Adewumi *et al.* (2016) desenvolveram quatro modelos diferentes de regressão vetorial de suporte (SVR) para estimar propriedades do concreto permeável, concluindo que os valores estimados concordam bem com os valores experimentais, obtendo valores para o coeficiente de determinação para dados de treino e teste, respectivamente, 0,9806 e 0,8174, para a resistência à compressão, 0,9974 e 0,8067, para resistência à tração, 1,00 e 0,85, para a densidade, e 0,9403 e 0,8697, para a porosidade.

Shirgir, Mamdoohi e Hassani (2015) e Pareek e Hong (2020) testaram a rede neural artificial (ANN) para prever propriedades do concreto permeável. Shirgir, Mamdoohi e Hassani (2015) obtiveram uma relação funcional confiável entre as variáveis independentes de entrada responsáveis pela variabilidade da permeabilidade e resistência à compressão. Embora Pareek e Hong (2020) apresentem em seu trabalho potencial de predição, os autores afirmam não ter encontrado resultados no nível exigido, uma vez que obtiveram valor de apenas 0,67 para o R^2 .

Shirgir, Mamdoohi e Hassani (2015) encontraram R^2 para a resistência à compressão de 0,922 para treino e 0,879 para teste, e para a permeabilidade de 0,918 para treino e 0,912 para teste, com valores mais altos para a permeabilidade quando comparado com a resistência à compressão, concluindo que os resultados podem ser empregados para predição quando não houver dados laboratoriais disponíveis.

Chen, Zhao e Bie (2020) aplicaram a rede neural de retroprogramação (BP), também pertencente ao modelo de rede neural artificial (ANN), para previsão de propriedades do concreto permeável, utilizando previsão unilateral e bilateral, verificando uma boa concordância entre os valores preditos e os valores medidos, com RMSE para ambas as previsões em relação a compressão igual a 0,24 MPa, e

de 0,09 mm/s para a previsão unilateral e 0,06 mm/s para previsão bilateral, em relação a permeabilidade a água. Dois modelos de predição com alta precisão foram construídos pelos autores.

4. FUNÇÃO DE DESEJABILIDADE

A função de desejabilidade, é uma ferramenta de otimização introduzida pela primeira vez por Harrington em 1965 (HARRINGTON, 1965), sendo o método mais popular proposto por Derringer e Suich (DERRINGER; SUICH, 1980), usada para problemas de otimização de resultados. Sua função é encontrar o equilíbrio entre diferentes propriedades, fornecendo a resposta desejada.


Uma função de desejabilidade é uma representação matemática de uma preferência na tomada de decisão, segundo um objetivo específico (CUMMINS; BELL, 2016), determinando as melhores condições de ajuste, otimizando simultaneamente múltiplas respostas.

A otimização permite encontrar uma configuração ideal dos parâmetros do processo, de modo que o produto possa ser produzido com as respostas ótimas ou próximas da ótima. A função de desejabilidade transforma diferentes variáveis respostas em uma só, através da combinação de respostas individuais em uma função composta, acompanhada de sua otimização (CANDIOTI *et al.*, 2014).

Para cada resposta predita Y_i , uma função de desejabilidade d_i , confere valores entre 0 e 1, como parâmetro. Esse parâmetro d_i , que nada mais é do que a resposta transformada, pode ter muitas formas diferentes. Independente da forma, $d_i = 0$ traduz um valor completamente indesejável de Y_i e $d_i = 1$ traduz um valor completamente desejável ou ótimo. As desejabilidade individuais são então combinadas por meio de média geométrica, fornecendo o valor de desejabilidade geral D (MONTEAGUDO *et al.*, 2008; CUMMINS; BELL, 2016; RODRÍGUEZ *et al.*, 2017). A desejabilidade geral ou global será um valor entre 0 e 1 e irá aumentar à proporção que os resultados se aproximem dos valores ideais.

A função de desejabilidade pode ser usada para encontrar valores mínimos, máximos ou valores alvos. O tipo de otimização dependerá do objetivo do estudo, maximizar, valor específico e minimizar, dos limites desejados, e do peso de cada resposta, que serão parâmetros base para o algoritmo (DERRINGER; SUICH, 1980). A Figura 4.1 demonstra graficamente o funcionamento da função de desejabilidade.

FIGURA 4.1 – Possibilidades da função de desejabilidade.



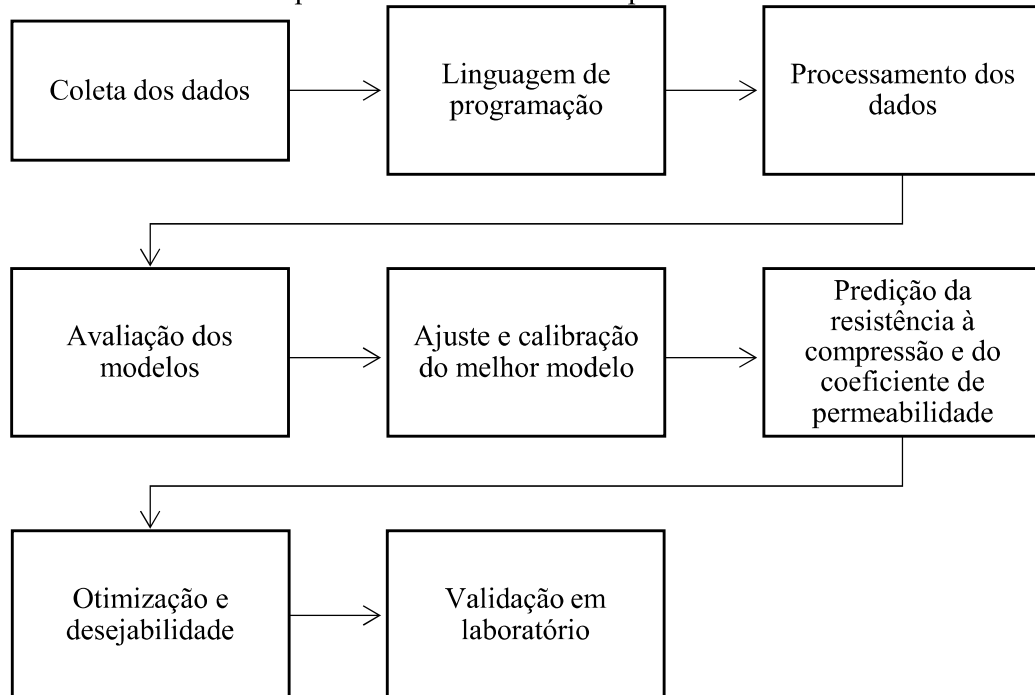
(a) Função de desejabilidade para maximizar; (b) Função de desejabilidade para valor específico e (c) Função de desejabilidade para minimizar.

Fonte: Pimenta *et al.* (2015)

5. MATERIAIS E MÉTODOS

Neste capítulo está apresentada, por meio da Figura 5.1, a metodologia utilizada no trabalho para a predição da resistência à compressão do concreto permeável e do seu coeficiente de permeabilidade.

Figura 5.1 – Metodologia para a predição da resistência à compressão e do coeficiente de permeabilidade do concreto permeável.



Fonte: o autor.

5.1 COLETA DE DADOS

Durante o levantamento bibliográfico realizado no periódico *Capes* (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), buscou-se trabalhos que relacionavam concreto permeável e aprendizagem de máquina, com ênfase na predição da resistência à compressão e coeficiente de permeabilidade.

A base de dados utilizada no presente trabalho foi obtida do trabalho de Zhang *et al.* (2020), intitulado como “A metaheuristic-optimized multi-output model for predicting multiple properties of pervious concrete”, apresentada no anexo A, e está disponível na base de dados *ScienceDirect* (Elsevier).

Noventa amostras de concreto com diferentes proporções foram estudadas, sendo que as variáveis de entrada consideradas são relação água/cimento (a/c), tamanho do agregado (diâmetro) e relação agregado cimento (ag/cim). As variáveis de saída são a resistência à compressão (MPa) e coeficiente de permeabilidade do concreto (mm/s).

Os parâmetros verificados na análise do trabalho de Zhang *et al.* (2020) estão apresentados na Tabela 5.1.

TABELA 5.1 – Parâmetros verificados no trabalho de Zhang *et al.* (2020).

| Dados | Valor Mínimo | Valor Máximo |
|---------------------------------------|---------------------|---------------------|
| Relação a/c | 0,25 | 0,50 |
| Tamanho do agregado (mm) | 3,50 | 13,00 |
| Relação ag/cim | 2,50:1 | 4,50:1 |
| Resistência à compressão (MPa) | 5,00 | 30,00 |
| Coefficiente de permeabilidade (mm/s) | 0,10 | 4,07 |

Fonte: o autor.

A relação a/c variara em 0,05, a relação e ag/cim em 0,50 e o tamanho dos agregados foram 3,50 mm, 7,5 mm e 13 mm. Além disso, os autores utilizaram aditivo superplastificante à base de policarboxilato na proporção de 2,50 kg/m³ de concreto, com o intuito de reduzir a quantidade de água aumentando a trabalhabilidade.

Todos os traços foram validados em laboratório sendo que os valores para a resistência à compressão e coeficiente de permeabilidade foram encontrados segundo as Especificações Técnicas Chinesas para Pavimento de Concreto Permeável CJJ/T 135 (2009), AS1012.9 (2014) e AS1012.14 (1991), respectivamente (ZHANG *et al.*, 2020).

Os autores aplicaram um modelo híbrido de inteligência artificial: regressão vetorial de suporte de mínimos quadrados multi-saída (MOLSSVR) com hiperparâmetros ajustados por um algoritmo de busca de antenas de besouro (BAS) modificado pela incorporação de peso de inércia autoadaptativo e voo de Levy.

5.2 LINGUAGEM DE PROGRAMAÇÃO

Linguagens computacionais permitem a execução de funções e outras operações matemáticas para uma vasta gama de dados e finalidades, possibilitando ao pesquisador alcançar novas ferramentas para a análise de dados. Metodologias de aprendizagem de máquina que se baseiam em linguagem de programação R são mais confiáveis e precisas (ARABAMERI *et al.*, 2018; HOSSEINALIZADEH *et al.*, 2019), sendo a linguagem computacional R a escolhida para o trabalho, por meio dos softwares R versão 4.2.2 e RStudio, utilizando as bibliotecas disponíveis no Quadro 5.1.

QUADRO 5.1 – Bibliotecas utilizadas.

| Pacotes | Descrição |
|----------------|---|
| caret | Funções diversas para treinar e traçar modelos de classificação e regressão |
| caretEnsemble | Estrutura para ajustar vários modelos usando a mesma estratégia de reamostragem, bem como criar conjuntos de tais modelos |
| corplot | Pacote de visualização de matriz de correlação |
| desirability | Cria funções de desejabilidade para uso na otimização de múltiplas respostas |
| GGally | Extensão para 'ggplot2'; Sistema de plotagem gráfica |
| ggplot2 | Pacote de visualização de dados na forma gráfica |
| moments | Calcula momentos, curtose de Pearson, curtose de Geary e assimetria e faz testes relacionados a eles |
| readxl | Ler arquivos do Excel |
| rpart | Particionamento recursivo e árvores de regressão |
| rpart.plot | Modelos 'rpart' de plotagem; adapta automaticamente o gráfico para o tipo de resposta do modelo |
| tidymodels | É uma coleção de pacotes para modelagem e análise estatística |
| tidyverse | Conjunto de pacotes que manipula, explora e visualiza os dados |

Fonte: Adaptado de RDocumentation (2022).

5.3 ANÁLISE DESCRITIVA DOS DADOS

Realizou-se a análise descritiva quantitativa dos dados brutos, AC (relação água/cimento), DIAM (diâmetro do agregado), AGCIM (relação agregado/cimento), COMP (resistência à compressão) e PERM (coeficiente de permeabilidade), com o intuito de organizá-los, resumi-los e descrever suas características. A análise descritiva permite uma melhor visualização dos dados e suas tendências, reduzindo o número de informações, demonstrando seus padrões e suas tendências. Através dessa análise, verificou-se os intervalos dos dados de entrada e saída, bem como sua média, variação, desvio padrão e assimetria, permitindo a comparação dos resultados com a literatura. Os parâmetros para análise descritiva foram obtidos utilizando as funções presentes no Quadro 5.2.

QUADRO 5.2 – Parâmetros utilizados para a análise descritiva.

| Parâmetros | Função | Descrição |
|--------------------------|---|--|
| Mínimo | $\min(x)$ | Valor mínimo encontrado |
| 1º Quartil | $\text{quantile}(x, 0.25)$ | Dividindo os dados em quatro partes iguais, são os valores referentes aos primeiros 25% |
| Mediana | $\text{median}(x)$ | O valor encontrado no meio do conjunto de dados, quando organizados de forma crescente |
| 3º Quartil | $\text{quantile}(x, 0.75)$ | Dividindo os dados em quatro partes iguais, são os valores referentes a faixa de 75% |
| Máximo | $\max(x)$ | Valor máximo encontrado |
| Amplitude | $(\max(x)-\min(x))$ | Diferença entre o valor mínimo e o valor máximo |
| Média | $\text{mean}(x)$ | Medida de tendência central |
| Desvio padrão | $\text{sd}(x)$ | Medida do grau de dispersão dos dados, desvio típico dos dados em relação à média |
| Variância | $\text{var}(x)$ | É uma medida de dispersão que mostra o quão distante cada valor desse conjunto está do valor central |
| Assimetria | $\text{skewness}(x)$ | Mede o grau de afastamento de uma distribuição em relação a um eixo central, geralmente a média |
| Curtose | $\text{kurtosis}(x)$ | Procura caracterizar a forma da distribuição quanto ao seu achatamento |
| Soma | $\text{sum}(x)$ | Soma de todos os dados |
| Nº dados | $\text{length}(x)$ | Quantidade de dados |
| Coefficiente de variação | $100*\text{sd}(x)/\text{mean}(x)$ | Varição dos dados obtidos em relação à média |
| Índice de variação | $\text{CV}/\text{sqrt}(\text{length}(x))$ | É um quociente que expressa a variação relativa entre os valores de qualquer medida |

Fonte: Adaptado de Mahoney (2019) e Soetewey (2020).

5.4 VERIFICAÇÃO DA CORRELAÇÃO DAS VARIÁVEIS

Interessados em determinar a correlação entre as variáveis, de modo a descobrir a influência de uma sobre a outra, utilizou-se como parâmetro o coeficiente de correlação amostral de Pearson (r ou ρ),

medindo quantitativamente, associando duas variáveis linearmente, assumindo valores entre 1 e -1, sendo que quanto maior o valor, em módulo, maior a correlação entre elas (MARTINS, 2014).

Callegari-Jacques (2003) classifica o coeficiente de correlação da seguinte forma:

se $|\rho|$ está entre 0,00 e 0,30, existe uma correlação linear fraca;

se $|\rho|$ está entre 0,30 e 0,60, existe uma correlação linear moderada;

se $|\rho|$ está entre 0,60 e 0,90, existe uma correlação linear forte;

se $|\rho|$ está entre 0,90 e 1,00, existe uma correlação linear muito forte.

5.5 AVALIAÇÃO INICIAL DO DESEMPENHO DOS MODELOS DE AM

Utilizando o pacote “caretEnsemble” foi possível comparar e analisar diversos algoritmos de aprendizagem de máquina, com o intuito de testar e classificar os dados de acordo com o melhor modelo. Os modelos testados foram random forest (RF), k vizinhos mais próximos (k-NN), redes neurais bayesianas regularizadas (brnn), boosted tree (*blackboost*), máquinas de vetor de suporte com kernel de função de base radial (*svmRadial*), *cubist* e máquinas de vetor de relevância com kernel de função de base radial (*rvmRadial*). Na Quadro 5.3 pode-se verificar os parâmetros de ajuste de cada modelo.

QUADRO 5.3 – Parâmetros de ajuste de cada modelo.

| ALGORITMOS | PARÂMETRO DE AJUSTE |
|----------------------------------|---|
| RF | Preditores selecionados aleatoriamente (mtry) |
| k-NN | Nº de vizinhos (k) |
| BRNN | Neurônios |
| Boosted Tree - <i>blackboost</i> | Nº de árvores e Profundidade |
| <i>svmRadial</i> | Sigma e custo (c) |
| <i>cubist</i> | Comitês e nº de vizinhos |
| <i>rvmRadial</i> | Sigma |

Fonte: Adaptado de Kuhn (2019).

Inicialmente foi adotado como padrão que 80% dos dados serão utilizados para treinamento e os outros 20% para teste, assim como no trabalho de Adewumi *et al.* (2016) e Le *et al.* (2022), utilizando os dados brutos. Essa separação entre dados de treino e teste é comumente chamada de *split*. Após o processamento, é possível a avaliação do comportamento de cada modelo e escolher o que obteve melhores resultados.

5.6 CALIBRAÇÃO DOS PARÂMETROS DE AJUSTE

Verificado o melhor algoritmo, sendo neste caso o modelo *cubist*, para a variável resistência à compressão, e do modelo *svmRadial*, para a variável coeficiente de permeabilidade, uma vez que os modelos apresentam o menor erro médio absoluto (MAE), realizou-se a calibração dos parâmetros para a otimização dos modelos.

Variou-se os dados de treinamento e teste de 5 em 5% entre os valores de 70 e 90%. Além disso, optou-se pelo método de validação cruzada com 5 repetições, para a obtenção o melhor *split*, ou seja, a melhor divisão entre os dados de treino e teste.

A validação cruzada foi realizada pelo método K-fold (BURMAN, 1989) com $cv = 5$, com o intuito de prevenir a seleção de modelos sobreajustados aos dados de treinamento e com baixa capacidade de generalização. Com esse método de reamostragem, os dados para treino foram divididos aleatoriamente em 5 parcelas (folds) distintos, de modo a ajustar o modelo, treinando-o e avaliando-o 5 vezes, sendo que em cada repartição, uma parcela diferente foi validada, sendo o resultado final a combinação das médias dos erros aferidos.

O melhor *split*, para cada modelo foi escolhido baseado no menor valor de MAE para cada um. Em seguida, ajustou-se os modelos, segundo seus parâmetros específicos, para a obtenção dos melhores resultados, otimizando o desempenho dos algoritmos. Para o *cubist*, resistência à compressão, os parâmetros ajustados foram o nº de comitês e o nº de vizinhos. Para a permeabilidade, os hiperparâmetros do modelo *svmRadial*, são C (custo) e σ .

Para o modelo *cubist*, os comitês foram escalonados de 1 a 30 e os vizinhos de 1 a 9, de modo que a buscar o melhor ajuste. Para o modelo *svmRadial*, o parâmetro σ foi dividido em 6 partes entre 0,1 e 0,5 e o custo em 7 partes de 6 a 12.

Definindo-se os parâmetros mais satisfatório para os ajustes dos modelos, obteve-se o menor valor possível de MAE. Foi possível também verificar o grau de importância de cada variável, e o seu coeficiente de determinação R^2 correspondentes aos dados de treino e de teste, comparando-os, sendo que, quanto maior o valor do R^2 , maior é o poder de explicação do modelo.

5.7 FERRAMENTAS DE AVALIAÇÃO DO DESEMPENHO DO MODELO

As ferramentas utilizadas para a avaliação do desempenho do modelo foram o coeficiente de determinação R^2 (Rsquared), a raiz quadrada do erro médio (Root Mean Squared Error – RMSE) e erro absoluto médio (MAE).

5.7.1 Coeficiente de determinação – R^2

O coeficiente de determinação R^2 ou Rsquared, que é uma medida de associação que representa a variância no valor da variável dependente que pode ser explicada pela variável independente (PAREEK; HONG, 2020), foi obtido pela relação numérica entre duas variáveis, variando de 0 a 1, avalia o quão próximo os dados se ajustam à linha de regressão, ou seja, quanto mais próximo de 1, maior é a correspondência entre os valores preditos e observados e pode ser calculado pela Equação 5.1.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5.1)$$

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.

5.7.2 Raiz quadrada do erro médio – RMSE

A raiz quadrada do erro médio (RMSE), que é um parâmetro amplamente utilizado na avaliação de modelos na aprendizagem de máquina, foi encontrado pela raiz quadrada da diferença entre os valores previstos pelo modelo e os valores reais observados, como mostra a Equação 5.2, sendo que os algoritmos de treinamento tiveram como finalidade a minoração do seu valor.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5.2)$$

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.

5.7.3 Erro absoluto médio – MAE

O erro absoluto médio (MAE) foi utilizado como um indicador popular, onde as unidades de valor de erro correspondem às unidades de valor alvo previstas assim como com o RMSE, sendo suas

mudanças são lineares e intuitivas. No modelo, erros diferentes não foram ponderados com mais ou menos, mas as pontuações aumentam linearmente com o aumento dos erros. Pode-se calculá-lo por meio da Equação 5.3.

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (5.3)$$

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.

5.8 FUNÇÃO DE DESEJABILIDADE

Como parte da otimização dos resultados, a função de desejabilidade, pertencente ao pacote *desirability*, foi utilizada predizer condições específicas. A desejabilidade foi um fator condicional para que o concreto permeável atingisse valores especiais. Para cada resposta predita, uma função de desejabilidade D , conferiu valores entre 0 e 1, sendo classificadas, segundo Para Derringer; Suich (1980), como consta no Quadro 5.4.

QUADRO 5.4 – Classificação da desejabilidade.

| CONDIÇÃO | CLASSIFICAÇÃO |
|------------------------|-----------------------------------|
| $D = 1$ | Valor desejável |
| $0,80 \leq D_i < 1$ | Valor excelente |
| $0,63 \leq D_i < 0,80$ | Valor está adequado |
| $0,40 \leq D_i < 0,63$ | Valor aceitável, mas pobre |
| $0,30 \leq D_i < 0,40$ | Valor no limite de aceitabilidade |
| $0 \leq D_i < 0,30$ | Valor fora da faixa adequada |

Fonte: Derringer; Suich (1980).

Três desejabilidades foram consideradas, utilizando como parâmetro a NBR 16416 (ABNT, 2015), que exige um valor mínimo de 20 MPa para a resistência à compressão e 1 mm/s para o coeficiente de permeabilidade.

Para desejabilidade 1 (D1) os valores requeridos foram máximo valor de resistência à compressão e máximo valor de coeficiente de permeabilidade, para a desejabilidade 2 (D2) valor de resistência à compressão alvo de 20 MPa e valor do coeficiente de permeabilidade alvo de 1 mm/s e para a desejabilidade 3 (D3) valor de resistência à compressão alvo 20 MPa e máximo valor de

coeficiente de permeabilidade, com no mínimo 1 mm/s. Para o caso das desejabilidades com resistência alvo de 20 MPa, o valor mínimo adotado foi de 19,99 MPa, de modo que não houvesse chance da função demonstrar valores menores, mesmo que próximos de 20 MPa.

5.9 VALIDAÇÃO DO MELHOR MODELO EM LABORATÓRIO

A validação depende dos valores obtidos segundo as desejabilidades do estudo e serve para verificar o funcionamento e a assertividade do modelo. As amostras produzidas foram testadas em relação a resistência à compressão.

5.9.1 Materiais

5.9.1.1 Cimento Portland

O cimento Portland usado como aglomerante foi o CP II Z-32, que leva em sua composição de 6 a 14% de material pozolânico e até 10% de material carbonático, podendo atingir até 40 MPa. Optou-se pelo consumo de 400 kg/m³, como nos trabalhos de Mulyono e Anisah (2019), Sun *et al.* (2019), Zheng *et al.* (2019) e Wu, Yu e Brouwers (2022).


5.9.1.2 Agregado graúdo

O agregado graúdo foi empregado em duas gradações, conhecidas popularmente como brita 1, com diâmetro entre 19 e 9,5 mm, e brita 0, com diâmetro entre 9,5 e 4,75 mm (Figura 5.2), proveniente da cidade de Catalão – Goiás. Para a obtenção da desejabilidade, os tamanhos médios dos agregados foram obtidos por meio da média ponderada de sua granulometria (Figura 5.3), são de 5,72 mm para a brita 0 e de 11,62 mm para a brita 1.

FIGURA 5.2 – Agregado graúdo “brita 1” (a) e “brita 0” (b).



Fonte: Acervo pessoal.

FIGURA 5.3 – Composição granulométrica do agregado graúdo.

Fonte: Próprio autor.

5.9.1.3 Aditivo superplastificante

O aditivo superplastificante de alto desempenho a base de polímeros de policarboxilato com função redutora de água, MC-PowerFlow 6480, na proporção fixa de 2,5 kg/m³. O material possui densidade de 1,08 kg/L. Este aditivo foi doado pela empresa MC-Bauchemie Brasil.

5.9.2 Preparação das amostras e testes

Os agregados foram secos em estufa por 24 horas na temperatura de $100 \pm 5^\circ \text{C}$.

Para a produção do concreto permeável, os materiais foram pesados e misturados, sendo que a água foi adicionada de forma particionada, avaliando-se o aspecto e a trabalhabilidade da mistura. Após a mistura de todos os materiais, realizou-se o “*slump test*”, ensaio que determina a consistência do concreto por meio do abatimento do tronco de cone, realizado segundo a NBR 16889 (ABNT, 2020).

Os corpos de prova foram moldados segundo a NBR 5738 (ABNT, 2015), sendo que foram produzidas 9 amostras por traço, em formato cilíndrico com dimensões de 100 x 200 mm. Utilizou-se a mesa vibratória durante 3 minutos, e, em seguida, eles foram compactados manualmente.

Os corpos de prova foram curados por cura úmida, com umidade relativa de $95\% \pm 5\%$ e temperatura de $20 \pm 1^\circ \text{C}$. Após a cura de 28 dias, eles foram testados em relação a de resistência à compressão uniaxial de acordo com as especificações da NBR 5739 (ABNT, 2018).

6. RESULTADOS E DISCUSSÕES

6.1 CARACTERIZAÇÃO DOS DADOS

O banco de dados utilizado, disponível no anexo A, é formado por 90 elementos, sendo três variáveis de entrada e duas variáveis de saída. Os resultados obtidos no artigo base utilizado no presente trabalho são fruto de uma análise laboratorial composta por traços de concreto permeável e suas respectivas respostas. Para a obtenção das variáveis de saída, Zhang *et al.* (2020) produziram 270 amostras de concreto, sendo três corpos de prova para cada traço, e o resultado obtido para cada ensaio, o valor médio entre eles. Os dados foram processados sem tratamento, ou seja, foram utilizados os dados brutos.

6.2 ANÁLISE DOS DADOS

A Tabela 6.1, mostra os resultados obtidos através da análise descritiva entre as variáveis estudadas, permitindo a verificação de seus padrões e limites, sendo possível a comparação entre eles.

Tabela 6.1 – Análise descritiva das variáveis do banco de dados utilizados para concreto permeável.

| | AC | DIAM | AGCIM | COMP | PERM |
|----------|-------|--------|--------|---------|--------|
| Min | 0,25 | 3,50 | 2,50 | 5,00 | 0,10 |
| Q_1,25% | 0,30 | 3,50 | 3,00 | 10,70 | 1,01 |
| Mediana | 0,38 | 7,50 | 3,50 | 14,90 | 1,68 |
| Q_3,75% | 0,45 | 13,00 | 4,00 | 20,48 | 2,46 |
| Max | 0,50 | 13,00 | 4,50 | 30,00 | 4,07 |
| Ampl | 0,25 | 9,50 | 2,00 | 25,00 | 3,97 |
| Media | 0,38 | 8,00 | 3,50 | 16,00 | 1,79 |
| SD | 0,09 | 3,92 | 0,71 | 6,58 | 1,00 |
| Var | 0,01 | 15,34 | 0,51 | 43,33 | 1,00 |
| Assim | 0,00 | 0,19 | 0,00 | 0,42 | 0,29 |
| Curt | 1,73 | 1,50 | 1,70 | 2,16 | 2,21 |
| Soma | 33,75 | 720,00 | 315,00 | 1439,90 | 161,22 |
| Nº dados | 90,00 | 90,00 | 90,00 | 90,00 | 90,00 |
| CV | 22,90 | 48,95 | 20,32 | 41,14 | 55,92 |
| IV | 2,41 | 5,16 | 2,14 | 4,34 | 5,89 |

AC = Relação água/cimento; DIAM = Diâmetro do agregado; AGCIM = Relação agregado/cimento; COMP = 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 e IV = índice de variação.

Fonte: o autor.

Verificou-se, observando a Tabela 6.1, que a resistência à compressão média é de 16 MPa, variando entre 5 e 30 MPa, sendo esses valores próximos aos sugeridos pela norma americana 522R-10

(ACI, 2010) de 2,8 a 28 MPa. Observou-se que os dados apresentaram elevado coeficiente de variação de 41,14%, com alta dispersão entre os resultados, e assimetria igual a 0,42.

O valor médio para o coeficiente de permeabilidade do concreto permeável encontrado por Zhang *et al.* (2020), foi de 1,79 mm/s, com valor mínimo de 0,10 mm/s e valor máximo de 4,07 mm/s, sendo que a maioria dos valores, como pode ser visto no resultado do primeiro quartil, atendem a norma brasileira NBR 16416 (ABNT, 2015), que exige que o concreto permeável tenha no mínimo permeabilidade igual a 1 mm/s.


Quando comparados, os resultados para a permeabilidade apresentaram menor assimetria e menor erro padrão do que os resultados para a resistência à compressão. Em relação ao coeficiente de variação, do índice de variação e a curtose, a permeabilidade apresentou valores mais altos, demonstrando maior dispersão entre os resultados.

Em relação as variáveis de entrada, observa-se que, que o diâmetro é o que apresenta maior amplitude, desvio padrão, variância e assimetria, o que já era esperado, uma vez que os tamanhos de agregados utilizados variam consideravelmente.

6.3 VERIFICAÇÃO DE CORRELAÇÃO ENTRE AS VARIÁVEIS

A correlação entre as variáveis estudadas, pode ser vista na Figura 6.1.

FIGURA 6.1 – Análise de correlação entre as variáveis de entrada e as variáveis resistência à compressão e coeficiente de permeabilidade.



AC = Relação água/cimento; DIAM = Diâmetro do agregado; AGCIM = Relação agregado/cimento e COMP = Resistência à compressão.

Fonte: o autor.

Por meio da Figura 6.1 verificou-se que o algoritmo não encontrou correlação entre a relação a/c e o diâmetro do agregado, entre a relação a/c e relação ag/cim e entre o diâmetro do agregado e a relação ag/cim . Em contrapartida, todas as variáveis de entrada possuem, mesmo que pequena, correlação com as variáveis de saída, resistência à compressão e coeficiente de permeabilidade, o que já era esperado.

Nota-se que a relação a/c é o fator que mais impacta no desempenho da resistência à compressão com $-0,45$, considerada, segundo Callegari-Jacques (2003), uma correlação linear moderada negativa, ou seja, o aumento da relação a/c afeta negativamente a resistência à compressão do concreto permeável, como sugere a bibliografia. Quanto a correlação entre diâmetro do agregado, relação ag/cim e a resistência é linearmente fraca, mas presente.

Foi possível notar que as variáveis de entrada geram impactos na variável de saída, como já era esperado. A correlação entre a/c e permeabilidade é de $-0,50$, considerada linearmente moderada negativa, ou seja, o seu impacto na permeabilidade é negativo, a correlação entre o diâmetro do agregado e a permeabilidade é de $0,53$, considerada linearmente moderada positiva, quanto maior for o tamanho do agregado, mais permeável será o concreto, e a correlação entre ag/cim e permeabilidade é de $0,63$, linearmente forte positiva, trazendo ganhos positivos para a permeabilidade.

Quando a correlação apresenta sinal negativo, significa que ocorre um impacto negativo entre as variáveis. Portanto, verificou-se que a relação a/c influencia de forma negativa tanto a resistência à compressão, quanto o coeficiente de permeabilidade, concordando com a verificação de Zhang *et al.* (2020). Com o aumento da relação a/c , diminui-se a resistência à compressão e a permeabilidade, concordando com Sun *et al.* (2019).

Uma observação interessante foi a correlação existente entre o coeficiente de permeabilidade e a resistência à compressão ter dado fraca, ou seja, por não estarem correlacionadas fortemente é um indício de que é possível conseguir atingir as metas de resistência e permeabilidade concomitantemente.

Além disso, comparando os valores de resultados da correlação entre a resistência à compressão e o coeficiente de permeabilidade, nota-se que as variáveis de entrada impactam mais na permeabilidade do que na resistência à compressão.

6.4 AVALIAÇÃO DE DESEMPENHO DOS MODELOS DE AM

Após a análise descritiva dos dados e da correlação entre as variáveis, efetuou-se o processamento dos mesmos, por meio do emprego de algoritmos preditivos da aprendizagem de máquina (RF, k-NN, brnn, *blackboost*, *svmRadial*, *cubist* e *rvmRadial*), em busca do melhor modelo.

Os dados foram executados conforme o *dataset* obtido de Zhang *et al.* (2020), utilizando o método de validação cruzada k-fold (cv), largamente aplicado no treinamento de dados, com número de

conjuntos k igual a 5, dividindo os dados aleatoriamente, treinando e avaliando o modelo, com *split* de 80% para treinamento e 20% para teste.

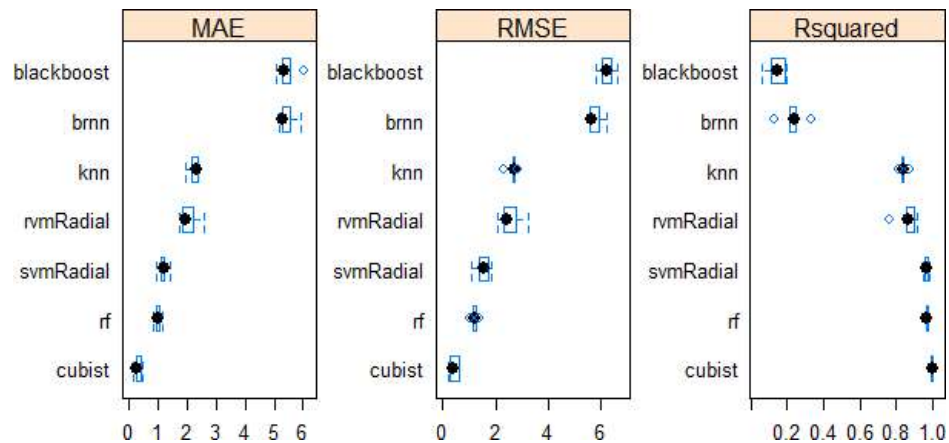
Para a escolha do melhor modelo de predição, realizou-se a análise dos dados de treinamento, comparando-os segundo o desempenho do coeficiente de determinação (R^2), como pode ser visto por meio da Tabela 6.2 e pela Figura 6.2.

TABELA 6.2 – Coeficiente de determinação em relação a resistência à compressão.

| | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|-------------------|--------|---------|--------|--------|---------|--------|
| rf | 0,9670 | 0,9673 | 0,9684 | 0,9718 | 0,9763 | 0,9801 |
| knn | 0,8157 | 0,8331 | 0,8418 | 0,8414 | 0,8438 | 0,8727 |
| brnn | 0,1282 | 0,2098 | 0,2424 | 0,2313 | 0,2480 | 0,3282 |
| <i>svmRadial</i> | 0,9544 | 0,9621 | 0,9638 | 0,9685 | 0,9735 | 0,9886 |
| <i>cubist</i> | 0,9897 | 0,9923 | 0,9981 | 0,9957 | 0,9990 | 0,9993 |
| <i>rvmRadial</i> | 0,7642 | 0,8612 | 0,8677 | 0,8618 | 0,9001 | 0,9156 |
| <i>blackboost</i> | 0,0616 | 0,1119 | 0,1495 | 0,1411 | 0,1844 | 0,1983 |

Fonte: o autor.

FIGURA 6.2 – Análise comparativa entre os algoritmos em relação a resistência à compressão.



MAE = Erro absoluto médio; RMSE = Raiz quadrada do erro médio e Rsquared = Coeficiente de determinação (R^2).

Fonte: o autor.

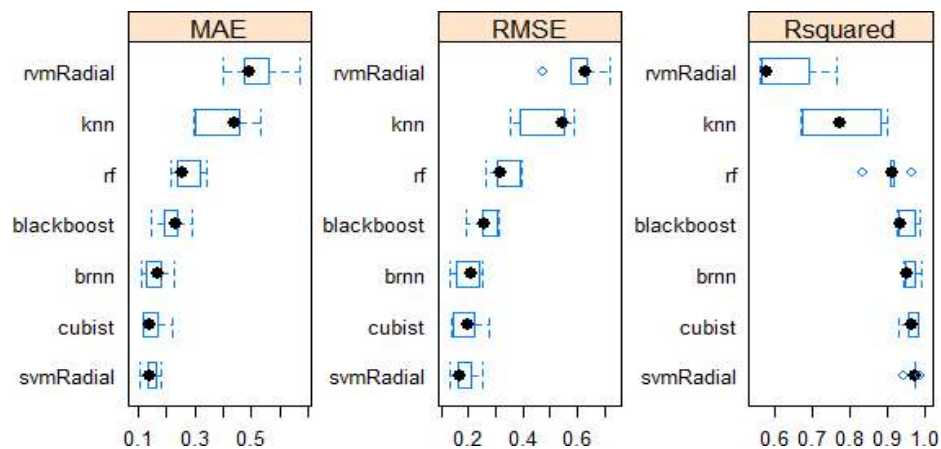
É possível constatar pela Figura 6.2, que o modelo *cubist* apresentou melhor resultado para os dados de resistência à compressão, possuindo maior potencial de generalização, em comparação com os demais algoritmos, com R^2 médio igual a 99,57%. O *cubist* demonstrou maior potencial de predição, consideravelmente superior aos outros, especialmente ao *blackboost*, que teve o pior desempenho, R^2 médio igual a 14,11%, valor muito inferior aos demais, verificando a inviabilidade de sua aplicação.

Em relação aos dados correspondentes ao coeficiente de permeabilidade, a Tabela 6.3 e Figura 6.3 relacionam o comportamento dos algoritmos com o R^2 .

TABELA 6.3 – Coeficiente de determinação em relação ao coeficiente de permeabilidade

| | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|-------------------|--------|---------|--------|--------|---------|--------|
| <i>rf</i> | 0,8357 | 0,9073 | 0,9148 | 0,9082 | 0,9164 | 0,9667 |
| <i>knn</i> | 0,6721 | 0,6726 | 0,7740 | 0,7806 | 0,8841 | 0,9005 |
| <i>brnn</i> | 0,9421 | 0,9457 | 0,9534 | 0,9612 | 0,9757 | 0,9893 |
| <i>svmRadial</i> | 0,9428 | 0,9719 | 0,9747 | 0,9699 | 0,9755 | 0,9848 |
| <i>cubist</i> | 0,9298 | 0,9549 | 0,9632 | 0,9629 | 0,9823 | 0,9845 |
| <i>rvmRadial</i> | 0,5622 | 0,5651 | 0,5795 | 0,6323 | 0,6909 | 0,7639 |
| <i>blackboost</i> | 0,9267 | 0,9292 | 0,9362 | 0,9505 | 0,9736 | 0,9865 |

Fonte: o autor

FIGURA 6.3 – Análise comparativa entre os algoritmos em relação ao coeficiente de permeabilidade.

MAE = Erro absoluto médio; RMSE = Raiz quadrada do erro médio e Rsquared = Coeficiente de determinação (R^2).

Fonte: o autor.

Como pode ser visto pela Tabela 6.3 e pela Figura 6.3, o melhor modelo para os dados relacionados ao coeficiente de permeabilidade é o *svmRadial*, com boa capacidade de generalização, como mencionado por Sun *et al.* (2019) e Ahmed *et al.* (2021), com coeficiente de determinação médio igual a 96,99%.

6.5 CALIBRAÇÃO DOS PARÂMETROS DE AJUSTE

Ainda que o modelo apresente bons resultados é possível otimizá-lo, ajustando seus parâmetros. Variou-se a quantidade de dados destinados para o treino e para teste, com o intuito de definir o melhor *split*, para o modelo *cubist*, ajustando os comitês e o nº de vizinhos, e, para o modelo *svmRadial*, ajustando o sigma e o custo.

6.5.1 Determinação da separação entre treino e teste e do método de controle

O melhor *split* é aquele que apresenta o melhor intervalo de separação entre os dados de treino e teste, calibrado de modo que se obtenha o resultado mais satisfatório para o coeficiente de determinação R^2 e para a raiz quadrada do erro médio (RMSE).

As análises dos resultados podem ser verificadas nas Tabelas 6.4, 6.5 e 6.6 que apresentam o estudo dos *splits* para os dados do *cupist*, para a resistência à compressão, e nas Tabelas 6.7, 6.8 e 6.9 para o estudo pelo método *svmRadial*, para o coeficiente de permeabilidade.

TABELA 6.4 – Erro absoluto médio (MAE) para o modelo *cupist* considerando diferentes combinações de dados para treino e teste, na predição da resistência a compressão

| Treino/Teste | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|--------------|--------|---------|--------|--------|---------|--------|
| 70/30 | 0,1846 | 0,2115 | 0,3094 | 0,3245 | 0,3451 | 0,5721 |
| 75/25 | 0,2230 | 0,2537 | 0,2579 | 0,2750 | 0,2896 | 0,3509 |
| 80/20 | 0,2001 | 0,2095 | 0,2252 | 0,2203 | 0,2254 | 0,2412 |
| 85/15 | 0,2095 | 0,2117 | 0,2403 | 0,2670 | 0,2637 | 0,4099 |
| 90/10 | 0,1604 | 0,2504 | 0,3047 | 0,3074 | 0,3106 | 0,5107 |

Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor

Tabela 6.5 – Raiz quadrada do erro médio (RMSE) para o modelo *cupist* considerando diferentes combinações de dados para treino e teste, na predição da resistência a compressão

| Treino/Teste | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|--------------|--------|---------|--------|--------|---------|--------|
| 70/30 | 0,2187 | 0,2540 | 0,4046 | 0,4504 | 0,4518 | 0,9228 |
| 75/25 | 0,2732 | 0,3194 | 0,3372 | 0,3398 | 0,3534 | 0,4159 |
| 80/20 | 0,2574 | 0,2628 | 0,2768 | 0,2802 | 0,2871 | 0,3167 |
| 85/15 | 0,2825 | 0,2908 | 0,2967 | 0,3660 | 0,3155 | 0,6447 |
| 90/10 | 0,2024 | 0,3435 | 0,3575 | 0,3958 | 0,3705 | 0,7050 |

Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor

Tabela 6.6 – Coeficiente de determinação R^2 (Rsquared) para o modelo *cupist* considerando diferentes combinações de dados para treino e teste, na predição da resistência a compressão

| Treino/Teste | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|--------------|--------|---------|--------|--------|---------|--------|
| 70/30 | 0,9788 | 0,9964 | 0,9984 | 0,9943 | 0,9988 | 0,9991 |
| 75/25 | 0,9957 | 0,9975 | 0,9976 | 0,9974 | 0,9978 | 0,9985 |
| 80/20 | 0,9979 | 0,9979 | 0,9981 | 0,9982 | 0,9985 | 0,9987 |
| 85/15 | 0,9928 | 0,9977 | 0,9979 | 0,9973 | 0,9990 | 0,9990 |
| 90/10 | 0,9910 | 0,9955 | 0,9978 | 0,9963 | 0,9981 | 0,9991 |

Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor

TABELA 6.7 – Erro absoluto médio (MAE) para o modelo *svmRadial* considerando diferentes combinações de dados para treino e teste, na predição do coeficiente de permeabilidade

| Treino/Teste | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|--------------|--------|---------|--------|--------|---------|--------|
| 70/30 | 0,1244 | 0,1526 | 0,1534 | 0,1547 | 0,1588 | 0,1842 |
| 75/25 | 0,1011 | 0,1132 | 0,1599 | 0,1438 | 0,1674 | 0,1773 |
| 80/20 | 0,1082 | 0,1424 | 0,1581 | 0,1498 | 0,1677 | 0,1729 |
| 85/15 | 0,0862 | 0,1252 | 0,1393 | 0,1373 | 0,1500 | 0,1858 |
| 90/10 | 0,1142 | 0,1293 | 0,1377 | 0,1408 | 0,1460 | 0,1769 |

Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor

TABELA 6.8 – Raiz quadrada do erro médio (RMSE) para o modelo *svmRadial* considerando diferentes combinações de dados para treino e teste, na predição do coeficiente de permeabilidade

| Treino/Teste | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|--------------|--------|---------|--------|--------|---------|--------|
| 70/30 | 0,1614 | 0,1744 | 0,1857 | 0,1849 | 0,1903 | 0,2130 |
| 75/25 | 0,1309 | 0,1386 | 0,1896 | 0,1768 | 0,2106 | 0,2144 |
| 80/20 | 0,1400 | 0,1812 | 0,1846 | 0,1916 | 0,2107 | 0,2415 |
| 85/15 | 0,1112 | 0,1626 | 0,1652 | 0,1735 | 0,1996 | 0,2288 |
| 90/10 | 0,1523 | 0,1589 | 0,1982 | 0,1868 | 0,2019 | 0,2226 |

Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor

TABELA 6.9 – Coeficiente de determinação R^2 (Rsquared) para o modelo *svmRadial* considerando diferentes combinações de dados para treino e teste, na predição do coeficiente de permeabilidade

| Treino/Teste | Min. | 1st Qu. | Median | Mean | 3rd Qu. | Max. |
|--------------|--------|---------|--------|--------|---------|--------|
| 70/30 | 0,9557 | 0,9762 | 0,9792 | 0,9763 | 0,9849 | 0,9854 |
| 75/25 | 0,9585 | 0,9650 | 0,9776 | 0,9727 | 0,9803 | 0,9821 |
| 80/20 | 0,9651 | 0,9703 | 0,9707 | 0,9723 | 0,9743 | 0,9809 |
| 85/15 | 0,9511 | 0,9615 | 0,9727 | 0,9716 | 0,9814 | 0,9912 |
| 90/10 | 0,9624 | 0,9754 | 0,9762 | 0,9767 | 0,9838 | 0,9857 |

Min = Mínimo; 1st Q = Primeiro quartil; Median = Mediana; Mean = Média; 3rd Q = Terceiro quartil; Max = Máximo.

Fonte: o autor

Comparando as Tabelas 6.4 a 6.6, verifica-se que, para o modelo *cubist*, os melhores resultados estão apresentados no *split* com 80% de dados destinados ao treinamento e com 20% dos dados destinados ao teste, com menor valor de RMSE médio, igual a 0,2871 MPa, e maior valor médio para coeficiente de determinação R^2 , igual a 0,9982. Asteris *et al.* (2021) também realizaram o particionamento entre treino e teste 80 e 20%.

Para o modelo *svmRadial*, referente ao coeficiente de permeabilidade, a melhor separação entre os dados de treino e teste foi de 85% e 15%, respectivamente, com menor RMSE médio, de 0,1735 mm/s, e maior valor de R^2 , 0,9716, como pode-se ser verificado nas tabelas 6.9 e 6.10.

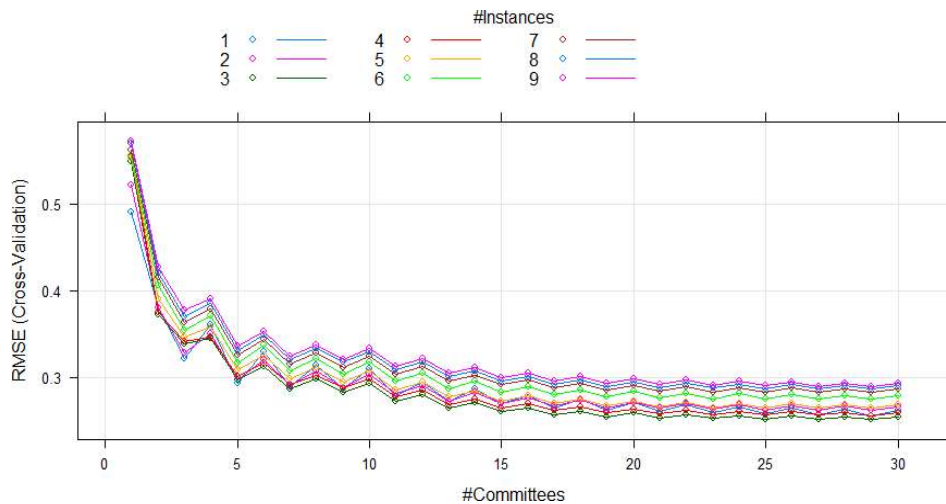
Ozcan, Kocak e Gulbandilar (2017) e Fonseca (2021) utilizaram o *split* em 85 para treino e 15% para teste e obtiveram, respectivamente, R^2 de 0,9639 e 0,8694, para o modelo no teste.

6.5.2 Determinação do número de comitês e vizinhos para o modelo *cubist*

Outra forma de otimizar os resultados e calibrar o algoritmo, é ajustar seus hiperparâmetros, conforme a indicação de cada modelo. Para o *cubist* o ajuste foi feito pelo número de comitês e vizinhos.

Inicialmente, optou-se por dividir os comitês em 30 partes (de 1 a 30) e o nº de vizinhos em 9 (de 1 a 9). Utilizou-se o menor resultado de RMSE para escolha do modelo ótimo, sendo 29 para o número de comitês, onde o erro foi estabilizado, e 3 para os vizinhos, ou seja, o modelo obteve melhor ajuste quando 3 vizinhos foram considerados. A Figura 6.4 ilustra como o melhor parâmetro foi identificado.

FIGURA 6.4 – Melhor ajuste para o modelo *cubist* na predição da resistência à compressão



Instances = instâncias/vizinhos; RMSE = Raiz quadrada do erro médio; Cross-Validation = Validação cruzada e Committees = comitês.

Fonte: o autor

Após o ajuste, o algoritmo apresentou os seguintes resultados para RMSE, R^2 e MAE, respectivamente, 0,2511 MPa, 0,9985 e 0,1963 MPa, sendo esses valores a combinação mais satisfatória do modelo, minimizando os erros.

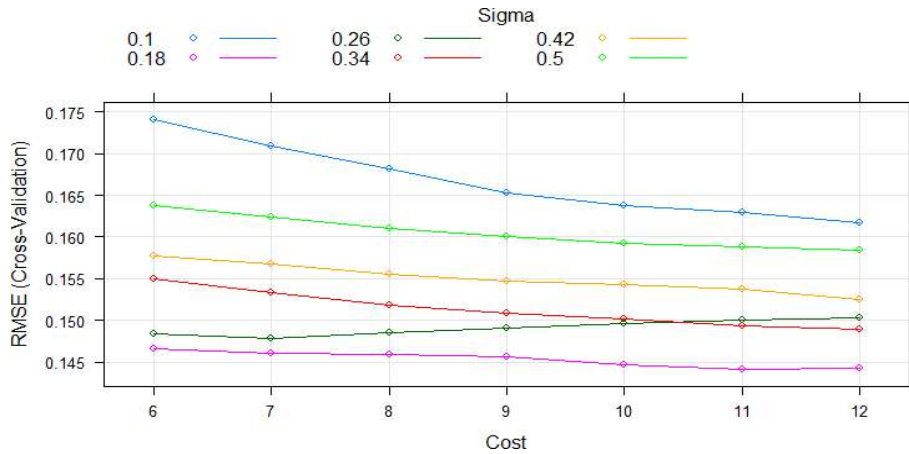
6.5.3 Determinação do sigma e custo para o modelo *svmRadial*

Para o modelo *svmRadial*, utilizado para a determinação do coeficiente de permeabilidade, os parâmetros de ajuste são o sigma e o custo. Para o sigma utilizou-se o intervalo entre 0,1 e 0,5, dividindo-o em seis partes, e para o custo utilizou-se em sete partes dentro do intervalo de 6 a 12.

Realizado o ajuste, é possível verificar que o melhor intervalo para o modelo é com o sigma igual a 0,18 e custo igual a 11, como pode-se verificar na Figura 6.5, por apresentar valores preferíveis de RMSE, R^2 e MAE, sendo eles 0,1442 mm/s, 0,9790 e 0,1203 mm/s, respectivamente. Sun *et al.*

(2019) encontraram o menor valor de RMSE de 0,1 mm/s para o ajuste de sigma igual a 0,004 e custo igual a 3,125.

FIGURA 6.5 – Melhor ajuste para o modelo *svmRadial* na predição do coeficiente de permeabilidade




Sigma = Peso; RMSE = Raiz quadrada do erro médio; Cross-Validation = Validação cruzada e Cost = custo.
Fonte: o autor.

6.5.4 Importância das variáveis de entrada e saída

A fim de determinar o grau de importância das variáveis de entrada sobre as variáveis de saída, temos as Figura 6.6, resistência à compressão e Figura 6.7, coeficiente de permeabilidade.

FIGURA 6.6 – Importância de cada variável em relação a resistência à compressão pelo modelo *cust*.




Feature = característica; Importance = importância; AC = água/cimento; DIAM = diâmetro; AGCIM = água/cimento.

Fonte: o autor.

Verificou-se, na Figura 6.6, que, para o *cust*, relação a/c tem uma importância de 100% sobre a resistência à compressão, ou seja, é a variável que mais a afetou, seguido pelo diâmetro do agregado que apresenta 71,58% de importância, sendo um valor considerável, enquanto a variável ag/cim apresenta importância igual a zero. Sun *et al.* (2019) verificaram que, ao contrário do presente trabalho, a relação ag/cim é a mais sensível sobre a resistência à compressão, seguida pela relação a/c e, por último, o diâmetro do agregado.

FIGURA 6.7 – Importância de cada variável em relação ao coeficiente de permeabilidade pelo modelo *svmRadial*.



Feature = característica; Importance = importância; AC = água/cimento; DIAM = diâmetro; AGCIM = água/cimento.

Fonte: o autor

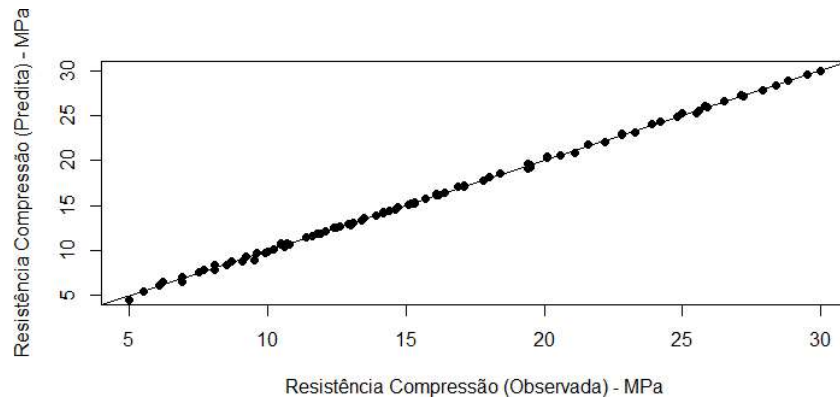
Em relação a importância das variáveis sobre o coeficiente de permeabilidade, utilizando o modelo *svmRadial*, foi possível verificar na Figura 6.7, o comportamento de cada uma, sendo que a que apresenta maior impacto é a relação agregado/cimento, concordando com Huang *et al.* (2020), com 100% de importância. Wang *et al.* (2019) e Zhang *et al.* (2020b) também afirmam que a relação ag/cim afetam diretamente a porosidade do concreto e sua permeabilidade.

A relação a/c também impacta a permeabilidade em 36,98%, enquanto o diâmetro do agregado não a afetou, considerando o banco de dados e modelos de predição utilizados. Diferente dos achados nesse trabalho, Sun *et al.* (2019) constataram que o nível de importância das variáveis de entrada sobre o coeficiente de permeabilidade são, respectivamente, diâmetro dos agregados, relação ag/cim e, por último, relação a/c.

Zhang *et al.* (2020) verificaram que a resistência à compressão diminui e a permeabilidade aumenta com o aumento da relação ag/cim. A permeabilidade aumenta e depois diminui com o aumento da relação a/c. A relação a/c também pode diminuir a resistência à compressão do concreto. No presente trabalho, foi verificado que, quando comparados, a relação ag/cim possui forte influência na permeabilidade, a relação a/c afeta tanto a permeabilidade quanto a resistência, sendo a resistência muito mais afetada pela relação, e que o diâmetro do agregado possui influência apenas na resistência à compressão. As diferenças entre os achados no trabalho e a literatura devem ser atribuídas as diferentes metodologias de estudo aplicadas e seus ajustes.

6.5.5 Avaliação dos algoritmos após calibração dos parâmetros

Após a realização de todos os ajustes possíveis, o modelo foi executado novamente, sendo possível analisar a correlação entre os valores reais e os valores preditos pelos modelos. A Figura 6.8 mostra a análise do modelo *cubist* para a resistência à compressão.

FIGURA 6.8 – Resistência à compressão real *versus* Resistência à compressão observada.

Fonte: o autor.

Analisando a Figura 6.8 verificou-se que os valores se mantiveram próximos ao ajuste ideal representado pela reta, mostrando uma boa relação entre os valores preditos e reais, confirmando a alta capacidade de generalização do modelo.

Na Tabela 6.10 é apresentado um resumo do desempenho do algoritmo *Cubist* na predição, após todo o processo de otimização, particionamento dos dados para treino e teste iguais a 80 e 20%, respectivamente, com divisão 5 subconjuntos, utilizando 29 comitês e 3 vizinhos.

TABELA 6.10 – Resumo final do modelo *Cubist* com os parâmetros ajustados.

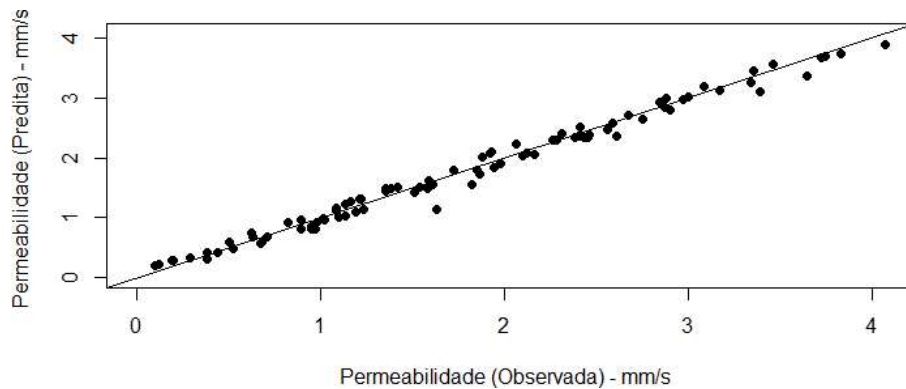
| Dados | R ² | MAE (MPa) | RMSE (MPa) |
|--------|----------------|-----------|------------|
| Treino | 0,9994 | 0,1179 | 0,1594 |
| Teste | 0,9987 | 0,1718 | 0,2287 |

Fonte: o autor.

Para a resistência à compressão, os valores de R² obtidos foram de 0,9994 para os dados de treinamento e 0,9987 para os dados de teste, valores preditivos satisfatórios, uma vez que estão próximos a 1, demonstrando a precisão do modelo.

Comparando com a literatura, o modelo *Cubist* se mostrou superior aos modelos utilizados por Shirgir, Mamdoohi e Hassani (2015), Adewumi *et al.* (2016), Zhang *et al.* (2020) e Le *et al.* (2022) para predição da resistência à compressão. Quando comparados a estudos que utilizaram o *Cubist*, como por exemplo os trabalhos de Lacoste *et al.* (2014), Houborg e McCabe (2018), Nguyen *et al.* (2019) e Zhou *et al.* (2019), os resultados do presente trabalho foram superiores.

Em relação aos valores preditos e reais obtidos pelo modelo *svmRadial* para o coeficiente de permeabilidade, observa-se a Figura 6.9.

FIGURA 6.9 – Coeficiente de permeabilidade real *versus* Coeficiente de permeabilidade observada.

Fonte: o autor.

Verificando a Figura 6.9, foi possível notar que, assim como para a resistência à compressão, os valores referentes ao coeficiente de permeabilidade encontram-se próximos a reta, que seria o ajuste perfeito. Na Tabela 6.11 é apresentado um resumo do desempenho do algoritmo *svmRadial* na predição da permeabilidade, pós ajustes, com o particionamento dos dados para treino e teste, de 85 e 15%, respectivamente, com sigma, ou peso igual a 0,18, e com custo igual a 11.

TABELA 6.11 – Resumo final do modelo *svmRadial* com os parâmetros ajustados.

| Dados | R ² | MAE (mm/s) | RMSE (mm/s) |
|--------|----------------|------------|-------------|
| Treino | 0,9887 | 0,0894 | 0,1047 |
| Teste | 0,9719 | 0,1314 | 0,1788 |

Fonte: o autor.

Por meio da Tabela 6.11 verificou-se que, após a otimização, o modelo *svmRadial*, para o coeficiente de permeabilidade, apresentou R² de 0,9887 para os dados de treino e 0,9719 para os dados de teste, demonstrando que o modelo proposto possui alto poder de explicação dos dados. Para a predição da permeabilidade, o modelo se mostrou superior aos utilizados por Shirgir, Mamdoohi e Hassani (2015), Huang *et al.* (2020) e Zhang *et al.* (2020).

O resultado para a resistência à compressão se mostrou ligeiramente superior ao do coeficiente de permeabilidade, sendo que em ambos, nota-se uma leve diminuição nos valores de R² do treino para o teste, o que significa que ocorreu um bom ajuste do modelo. Concordando com a bibliografia. Os valores obtidos confirmam a precisão dos modelos propostos.

6.6 DESEJABILIDADE

A Tabela 6.12 apresenta os resultados das três combinações preteridas, de modo exatamente ajustado as propriedades desejadas.

TABELA 6.12 – Desejabilidades – Traços ideais.

| Desejabilidade | D _{comp} (MPa) | D _{perm} (mm/s) | a/c | TAG (mm) | ag/cim | COMP (MPa) | PERM (mm/s) | D _g |
|----------------|----------------------------|-----------------------------|-------|-------------|--------|---------------|----------------|----------------|
| D1 | > valor | > valor | 0,275 | 4,75 | 4,5:1 | 30,88 | 2,82 | 0,7731 |
| D2 | 20 | 1 | 0,475 | 6,3 | 3,9:1 | 20,65 | 1,1 | 0,9618 |
| D3 | 20 | > valor (mín 1) | 0,325 | 9,5 | 4,5:1 | 20,34 | 3,54 | 0,9289 |

D_{comp} = Desejabilidade para compressão; D_{perm} = Desejabilidade para permeabilidade; a/c = Relação água/cimento; TAG = Tamanho do agregado graúdo; ag/cim = Relação agregado/cimento; COMP = Resistência à compressão; PERM = Coeficiente de permeabilidade; D_g = Desejabilidade geral.

Fonte: o autor.

A Tabela 6.12 mostra que a função de desejabilidade otimizou os traços de forma aceitável, chegando aos melhores resultados possíveis de acordo com suas múltiplas condições previamente estabelecidas.

Todos os traços otimizados obtiveram bons resultados, sendo D2 e D3 acima de 0,9, considerados valores excelentes, ou seja, os mesmos conseguiram se aproximar o máximo possível do desejado. A D1 apresentou um valor de desejabilidade inferior aos demais, mas ainda sim, um valor considerado adequado, que atende a normativa, não atingindo valores próximos de 1, pois as maiores resistências foram verificadas em concretos com menores permeabilidade e maiores permeabilidades em concretos com maiores resistências. De tal forma não atingir valor 1 na desejabilidade, não é um problema, mas sim o valor que conseguiu resultar na melhor combinação de variáveis de entrada para se atingir a maximização dos valores duas entradas de saída.

Sonebi e Bassuoni (2013) em seu trabalho intitulado como “*Investigating the effect of mixture design parameters on pervious concrete by statistical modelling*” obtiveram o valor de desejabilidade global de 0,931 na otimização de proporções de concreto permeável. Alterando apenas uma das variáveis, os autores perceberam que esse valor caiu para 0,804 demonstrando a complexidade da análise de problemas com variáveis multiparamétricas, concluindo que a mudança de qualquer fator, afeta o resultado final.

Quanto mais próximo de 1 estiver a desejabilidade global, mais desejável é o resultado, ou seja, o resultado chegou a melhor otimização, por meio do melhor ajuste dentre de suas múltiplas respostas, segundo os parâmetros requeridos previamente.

A otimização via desejabilidade, determinou os valores ótimos para cada traço de concreto permeável requerido, atendendo os valores mínimos estabelecidos pela NBR 16416 (ABNT, 2015). As combinações forneceram dados enxutos, de forma rápida, o que possibilita reduzir custos de laboratório, sendo que esses resultados dificilmente seriam atingidos por meio de testes laboratoriais aleatórios, dando um melhor direcionamento à pesquisas e dosagens ótimas para empresas.

Além disso, a função de desejabilidade possibilitou a previsão e identificação de forma simultânea das condições experimentais mais adequadas para todas as variáveis testadas no estudo, assim como no trabalho de Garcia e Pereira-Filho (2015), sendo possível encontrar resultados personalizados para cada tipo de traço estudado. Analisando a Tabela 6.12, nota-se que a desejabilidade

2 (D2) apresenta o traço ideal, que ficou mais próximo possível dos valores desejados (20 MPa e 1 mm/s, atender a normativa), segundo as variáveis de entrada, com maior valor de desejabilidade global.

6.7 VALIDAÇÃO DO MODELO

Para a validação do modelo, executou-se em laboratório traços baseados nas desejabilidades propostas na Tabela 6.12. Esperava-se que a validação do modelo fosse executada nas mesmas condições do banco de dados para que fosse possível atingir os valores preditos desejados, para que de fato o modelo pudesse ser validado, o que não foi exequível. Buscou-se então as condições mais próximas de replicar as misturas realizadas pelo laboratório chinês.

Os traços precisaram ser adaptados durante sua execução, com base no comportamento dos materiais à medida que estavam sendo misturados. Para os agregados graúdos, por exemplo, a desejabilidade indicava o uso de tamanhos específicos e na execução foram utilizados faixas de tamanhos. A medida que os materiais eram misturados, percebeu-se um excesso de água na mistura e optou-se pela redução da mesma e ajuste da quantidade de cimento e de agregado graúdo, que podem ser vistos na Tabela 6.13.

TABELA 6.13 – Traços práticos – adaptados dos traços da desejabilidade para as condições possíveis de serem executadas no laboratório.

| Traço | a/c | Tipo e TAG _m (mm) | ag/cim | Resistência à compressão predita (MPa) | Coefficiente de permeabilidade predito (mm/s) |
|-------|-------|---------------------------------|--------|--|---|
| TP1 | 0,264 | Brita 0 (5,72) | 4,5:1 | 29,32 | 2,95 |
| TP2 | 0,25 | Brita 0 (5,72) | 4,1:1 | 28,92 | 2,64 |
| TP3 | 0,205 | Brita 1 (11,62) | 4,12:1 | 17,69 | 3,11 |

TP = Traço prático; a/c = Relação água/cimento; TAG_m = Tamanho médio do agregado graúdo; ag/cim = Relação agregado/cimento.

Fonte: o autor.

Com a adição de superplastificante era esperado que o comportamento do concreto fosse alterado, o deixando mais trabalhável, entretanto, com a quantidade utilizada, a mistura se mostrou excessivamente fluída.

No TP1 a quantidade de água foi alterada com o intuito de minimizar o impacto do excesso de pasta de cimento na mistura que estava visivelmente superior ao necessário, apresentando comportamento extremamente fluído.

No TP2 optou-se por adicionar apenas aproximadamente a metade da quantidade inicial de água, a fim de observar o comportamento da mistura, para determinar se ela necessitava dos outros 50% restante, como era o previsto na desejabilidade D2, que representa o traço ideal. Mesmo com apenas metade da quantidade de água, o concreto apresentava excesso de água, por isso optou-se pela adição de agregados graúdos, ou seja, mais material granular para ser coberto com pasta.

No TP3 a água foi adicionada em porcentagens menores, até que a massa apresentasse um aspecto mais áspero condizente com o comportamento do concreto permeável, resultando na diferença entre o traço ideal previsto e o traço prático executado.

6.7.1 *Slump test*

O comportamento do concreto permeável, como já era esperado, foi alterado com a adição do aditivo superplastificante. A trabalhabilidade desse tipo de concreto costuma ser baixa e para medi-la, o ensaio de abatimento de tronco de cone, “*slump test*”, que verifica a consistência do material medindo o quanto ele cedeu, ou abaixou, quando o molde é retirado, foi realizado, segundo a NBR 16889 (ABNT, 2020), sendo seus resultados expostos na Tabela 6.14.

TABELA 6.14 – *Slump test*.

| TRAÇO | SLUMP (mm) |
|-------|------------|
| 1 | 20 |
| 2 | 21 |
| 3 | 0 |

Fonte: o autor.

Como pode ser visto na Tabela 6.14, foi possível verificar que os traços 1 e 2, apresentaram “*slumps*” semelhantes, diferentes de zero, demonstrando que o concreto apresentava alta trabalhabilidade mesmo com relações a/c baixas, devido a adição do superplastificante.

Já o traço 3, que possui uma relação a/c muito baixa, inferior aos demais traços e os parâmetros sugeridos pela 522R-10 (ACI, 2010), não obteve “*slump*”, ou seja, o seu abatimento foi 0 mm, apresentando uma mistura mais seca e áspera, difícil de moldar, mesmo com a utilização do aditivo superplastificante, como pode ser visto na Figura 6.10.

FIGURA 6.10 – *Slump test* traço 3.



Fonte: Acervo pessoal.

De maneira geral, o concreto permeável é um material com baixo teor de pasta de cimento e à medida que os traços foram sendo executados, foi possível verificar como os mesmos estavam se comportando, notando a segregação entre os agregados e a pasta, que se depositou no fundo dos corpos de prova.

6.7.2 Ensaio de resistência à compressão

Para determinar a resistência à compressão do concreto permeável, realizou-se o ensaio aos 28 dias, segundo as prescrições da NBR 5739 (ABNT, 2018). Como já era esperado, os resultados de resistência à compressão foram inferiores aos previstos, pois, além dos traços terem passado por ajustes, não foi possível reproduzir as mesmas condições de execução do trabalho base de Zhang *et al.* (2020). Os corpos de prova, que podem ser vistos na Figura 6.11, não apresentaram uniformidade, ocorrendo a segregação da mistura, influenciando fortemente sua resistência à compressão.

FIGURA 6.11 – Corpos de prova moldados em laboratório.



(a) Amostras referentes ao traço 1; (b) Amostras referentes ao traço 2; (c) Amostras referentes ao traço 3.

Fonte: Acervo pessoal.

Uma análise descritiva dos resultados obtidos experimentalmente pode ser vista na Tabela 6.15. As siglas são formadas por CP (corpo de prova) seguido pelo número do mesmo.

Tabela 6.15 – Resultado do ensaio de resistência à compressão.


| TRAÇO 1 | Resistência à compressão (MPa) | TRAÇO 2 | Resistência à compressão (MPa) | TRAÇO 3 | Resistência à compressão (MPa) |
|---------------|--------------------------------|---------------|--------------------------------|---------------|--------------------------------|
| CP1 | 13,70 | CP1 | 8,80 | CP1 | 8,80 |
| CP2 | 8,24 | CP2 | 8,10 | CP2 | 5,34 |
| CP3 | 9,29 | CP3 | 6,73 | CP3 | 9,71 |
| CP4 | 8,54 | CP4 | 7,79 | CP4 | 7,28 |
| CP5 | 9,54 | CP5 | 5,35 | CP5 | 9,24 |
| CP6 | 11,75 | CP6 | 5,96 | CP6 | 3,46 |
| CP7 | 7,97 | CP7 | 11,18 | CP7 | 8,02 |
| CP8 | 7,07 | CP8 | 9,66 | CP8 | 5,96 |
| CP9 | 10,01 | CP9 | 8,80 | CP9 | 11,15 |
| <i>Média</i> | 9,57 | <i>Média</i> | 8,04 | <i>Média</i> | 7,66 |
| Mínimo | 7,07 | Mínimo | 5,35 | Mínimo | 3,46 |
| Máximo | 13,70 | Máximo | 11,18 | Máximo | 11,15 |
| Amplitude | 6,63 | Amplitude | 5,83 | Amplitude | 7,69 |
| Desvio padrão | 1,94 | Desvio padrão | 1,73 | Desvio padrão | 2,27 |

Fonte: o autor.

No traço 1 os resultados variaram entre 7,07 e 13,70 MPa com amplitude de 6,63 MPa. No traço 2 a os valores variaram de 5,35 a 11,18 MPa com 5,83 MPa de amplitude. Já o traço 3 apresentou valores entre 3,46 e 11,15 MPa com amplitude igual a 7,69 MPa, sendo o último o que apresentou maior diferença entre seus resultados.

Os valores médios encontrados para a resistência à compressão estão ilustrados na Figura 6.12, sendo que o melhor comportamento foi o do traço 1, como já era esperado, com 9,57 MPa, sendo esse valor muito inferior ao mínimo exigido pelo NBR 16416 (ABNT, 2015) para aplicação do concreto permeável como pavimento, 20 MPa.

FIGURA 6.12 – Comparação entre os valores médios de resistência à compressão.



Fonte: o autor.

A diferença prática entre os traços 2 e 3 são a granulometria do agregado graúdo e a quantidade de água. A faixa de agregados usada pelo traço 2 foi de 4,75 a 9,5 mm, e no traço 3 foi de 9,5 a 19 mm. As relações a/c foram de 0,25 e 0,205, respectivamente, demonstrando que essas alterações impactaram negativamente no resultado final do traço 3, que foi inferior ao 2.

6.7.3 Comparação entre os valores preditos e os valores reais obtidos em laboratório

A Tabela 6.16 apresenta a comparação entre resultados preditos dos traços práticos e os resultados médios obtidos experimentalmente no presente estudo para a resistência à compressão, sendo possível notar a diferença entre os resultados.

TABELA 6.16 – Comparação entre os resultados preditos nos traços práticos e os resultados obtidos para resistência à compressão.

| TRAÇO | Valores de resistência à compressão preditos (MPa) | Valores de resistência à compressão obtidos (MPa) | Variação (MPa) |
|-------|--|---|----------------|
| 1 | 29,32 | 9,57 | 19,75 |
| 2 | 28,92 | 8,04 | 20,88 |
| 3 | 17,69 | 7,66 | 10,03 |

Fonte: o autor.

A maior variação entre os valores preditos e os valores reais foi verificada no traço 2, com variação de mais de 20 MPa, e a menor foi o traço 3 que apresentava menor previsão.

Nos traços 1 e 2, que apresentaram melhores resultados, foram usados agregados de gradação entre 4,75 e 9,5mm, concordando com Yang e Jiang (2003) que afirmam que agregados menores podem atingir resistências maiores. Liu *et al.* (2020) reiteram que em concretos permeáveis, sem agregado miúdo, a resistência à compressão é minimizada com o aumento no tamanho do agregado, acima de 10 – 15 mm.

No traço 3, que utilizou a faixa de agregados entre 9,5 e 19 mm, mesmo com o uso do superplastificante teve o valor médio de resistência à compressão inferior aos demais, indicando a influência do tamanho dos agregados em sua resistência mecânica.

Outro fator que também deve ter influenciado a baixa resistência do traço 3, assim como afirmam Lim *et al.* (2013), é sua baixa relação água/cimento, inferior ao indicado pela 522R-10 (ACI, 2010), que mesmo com o emprego de aditivos, deixou a massa muito seca e quebradiça, levando a uma resistência à compressão mais baixa.

Analisando os resultados de maneira geral, é possível constatar que o traço 3 teve o pior desempenho, menor valor médio de resistência à compressão, maior desvio padrão e maior variação. Quando comparado aos demais, o traço 1 foi o que apresentou melhores resultados.

Em todos os traços ocorreu a deposição de pasta de cimento ao fundo dos corpos de prova. A não uniformidade em um mesmo corpo de prova, levou a diminuição de sua resistência. A parte inferior

acabou apresentando uma superconcentração de material, não atingindo o objetivo desse tipo de concreto, ser permeável, e a parte superior ficou demasiadamente porosa e logo, frágil, deixando os agregados graúdos praticamente expostos. Como pode ser visto na Figura 6.13, em todos os traços, o corpo de prova foi rompido na parte superior, como já era esperado.

Figura 6.13 – Corpos de prova após serem rompidos.



(a)

(b)

(c)

(a) Amostras referentes ao traço 1; (b) Amostras referentes ao traço 2; (c) Amostras referentes ao traço 3.

Fonte: Acervo pessoal.

O superplastificante influencia significativamente o resultado da resistência à compressão e esse resultado nem sempre é positivo. Neste caso, o emprego do superplastificante ocasionou uma superfluidez no concreto, levando a segregação entre pasta de cimento e os agregados, ocorrendo a separação da mistura, concentrando a pasta no fundo das amostras, cobrindo todos os vazios, deixando a parte superior pobre, com baixo teor de material ligante e extremamente porosa, com o aspecto de um amontoado de agregados.

Ainda que o superplastificante seja adicionado com o intuito de melhorar a fluidez da pasta, se dosado errado, pode acabar afetando-a de forma prejudicial, fazendo com que a pasta escorra e se acumule no fundo, como aconteceu no presente estudo, concordando com Yang *et al.* (2021).

Liu, Tan e Fwa (2013) obtiveram resultados que mostraram aumento no índice de segregação da pasta à medida que se aumentava a dosagem de superplastificante e a relação água/cimento. O acréscimo da relação a/c gerou um maior volume de pasta que acabou ultrapassando a quantidade necessária para encapsular os agregados, sendo que essa sobra causou a obstrução dos poros do concreto permeável, reduzindo sua permeabilidade e aumentando a resistência à compressão, assim como afirmam Sonebi e Bassuoni (2013).

Cheung, Roberts e Liu (2018) afirmam que níveis altos de adição de superplastificante podem minimizar a quantidade de água no concreto em um grau desfavorável, como aconteceu no traço 3, atrapalhando o processo de hidratação do concreto, diminuindo sua resistência mecânica.

Outros fatores relevantes são que misturas de concreto permeável possuem secagem mais rápida (JIMMA; RANGARAJU, 2015), e um alto volume de SP leva ao aumento da incorporação de ar na mistura de concreto (MOURA *et al.*, 2021), o que também deve ter influenciado na redução das resistências do presente estudo.

O superplastificante não absorvido, se concentrou na parte inferior do corpo de prova, por gravidade, formando uma película impermeável, afetando a resistência e a permeabilidade do concreto de forma negativa.

Ainda que outros fatores possam ser levados em consideração como explicação da diferença no comportamento das misturas e entre os valores preditos e obtidos, as condições de execução devem ser consideradas como o fator preponderante na diferença entre os valores preditos e os obtidos em laboratório, uma vez que este trabalho se baseou no estudo chinês de Zhang *et al.* (2020) e não foi possível replica-lo com os mesmos parâmetros.

Cabe destacar as possíveis causas nessas diferenças: o tipo e composição do cimento, tipo, qualidade e graduação do agregado graúdo, uma vez que no trabalho os autores citam que foram usadas três graduações 13 mm, 7,5 mm e 3,75 mm, tipo, princípios ativos, composição e concentração do aditivo superplastificante, formato dos corpos de prova, uso da mesa vibratória por 1 minuto e o uso de prensa de pressão por 3 minutos.

No laboratório, buscou-se executar as misturas de concreto da melhor forma possível, entretanto, em trabalhos de reprodução, há uma discrepância nas condições e nos materiais utilizados, especialmente por se tratar de um trabalho chinês. Não foi possível garantir o emprego do mesmo tipo cimento, agregado e superplastificante, o tamanho dos agregados, se eram tamanho único ou diâmetro máximo ou como eles chegaram nos tamanhos utilizados, e das mesmas condições de preparação das amostras, vibroprensagem.

Dito isso, todas essas variáveis divergentes e problemas na execução devem ser levadas em consideração ao comparar os resultados do banco de dados que foi usado para a determinação da desejabilidade e os valores alcançados no laboratório.

A diferença entre a predição e validação do modelo em laboratório demonstrou a necessidade de maior detalhamento dos materiais, processos e considerações para sua reprodução. Caso tivesse sido possível validar o modelo, seria possível obter melhores direcionamentos para a dosagem de misturas de concreto permeável, minimizando custos de testes experimentais.

Assim como afirmam Sun *et al.* (2019), propriedades do concreto permeável como resistência à compressão e permeabilidade, dependem do controle de diversos outros fatores além das variáveis de entrada aqui estudadas, como o seu processo de cura, a composição e quantidade de superplastificante, composição e consumo do cimento, adição de agregado miúdo, qualidade dos agregados, variação nos

intervalos ou dimensões dos agregados, tipo e quantidade de tempo de vibração, tipo de compactação, etc.

Novas pesquisas, com bancos de dados realizados sob nossas condições de execução devem ser executadas a fim de validar tais modelos, utilizando a tecnologia em benefício da ciência, além de propiciar a difusão do pavimento de concreto permeável.

6.7.4 Permeabilidade

Para determinar o coeficiente de permeabilidade a proposta inicial seria, assim como Zhang *et al.* (2020), realizar o ensaio adaptado, segundo a norma chinesa CJJ/T 135 (2009), entretanto, como foi visto na Figura 5.11, todas as amostras apresentaram segregação entre a pasta de cimento e os agregados graúdos, ocorrendo a deposição da pasta no fundo dos corpos de prova, criando uma barreira que bloqueou a passagem da água, inviabilizando o ensaio. Observou-se ainda que o traço 2, que possui a maior concentração de cimento, apresentou a maior segregação.

Em decorrência da pasta de cimento ter se mostrado muito fluída, não foi possível criar uma película de espessura considerável envolta de todos os agregados. A pasta estava em excesso e escorreu, obstruindo os vazios do fundo dos corpos de prova, deixando a interface agregado pasta fraca que, como já visto diminuiu sua resistência mecânica, e acabou impedindo a percolação da água entre sua estrutura, deixando-o impermeável na parte inferior.

7. CONSIDERAÇÕES FINAIS

Com o intuito de mitigar recursos com testes laboratoriais, o uso de modelos de aprendizagem de máquina se mostrou confiável e vantajoso, com bom poder preditivo. Os algoritmos *cubist* e *svmRadial* apresentaram boa capacidade de generalização que, após otimizado, resultaram em altos valores de coeficientes de determinação e erros relativamente baixos.

O modelo de inteligência artificial proposto demonstrou uma relação funcional entre os dados de entrada e saída, útil na predição e otimização da resistência à compressão e do coeficiente de permeabilidade do concreto permeável, quando não for possível ou viável fazer o estudo em laboratório e para melhorar os resultados dessas propriedades.

Para a resistência à compressão, o modelo *cubist* alcançou um coeficiente de determinação de 99,87% com RMSE de 0,2287 MPa. Para o coeficiente de permeabilidade, o modelo *svmRadial* encontrou o valor de R^2 de 97,19% e RMSE de 0,1314 mm/s, ambos para dados de teste, demonstrando ótimo poder preditivo.

Além disso, a função de desejabilidade se apresentou como uma excelente ferramenta de otimização que permitiu verificar o traço que melhor se ajustou aos parâmetros previamente requeridos.

Por meio da aprendizagem de máquina verificou-se que a relação a/c possui a maior importância sobre a resistência à compressão, afetando negativamente essa propriedade. O diâmetro dos agregados também mostra alta importância na resistência, em quanto a relação ag/cim não se mostrou relevante.

Em relação a permeabilidade, o fator mais importante foi a relação ag/cim, sendo essa sua variável mais significativa, concordando com Huang *et al.* (2020). A relação a/c também se apresentou importante na permeabilidade. O diâmetro do agregado não demonstrou importância.

As diferenças encontradas no presente trabalho, quando comparadas com os achados por Sun *et al.* (2019) por exemplo, quanto ao grau de importância das variáveis de entrada nas variáveis de saídas, podem ser explicadas pela aplicação de modelos e ajustes diferentes utilizados nas predições.

A validação do modelo pretendia verificar a assertividade das previsões realizadas com o intuito de mitigar os custos de laboratório, diminuindo a quantidade de ensaios necessários para estudos sobre dosagem de concretos permeáveis, de modo a difundir seu uso, entretanto, não foi possível reproduzir as mesmas condições de execução do banco de dados do trabalho chinês, levando a discrepância entre os valores preditos e obtidos no laboratório.

Durante a execução da validação do modelo, os traços de concreto permeável precisaram passar por adequações de acordo com o comportamento dos materiais. As misturas apresentaram excesso de fluidez, o que levou a segregação da mistura. Esse acúmulo de pasta no fundo dos corpos de prova impactou diretamente na sua resistência à compressão, com valores obtidos bem inferiores aos valores preditos, e acabou impossibilitando a realização do ensaio que determina o coeficiente de permeabilidade do concreto.

Observou-se a limitação da pesquisa quanto ao uso de bancos de dados disponíveis com dados de concreto permeável, bem como a quantidade de amostras, considerada pequena, no banco de dados utilizados para o treinamento do modelo.

Ainda que a aprendizagem de máquina para a predição e otimização de propriedades do concreto venha sendo estudada há muitos anos, nota-se uma lacuna entre a previsão e a validação laboratorial. Há inúmeras restrições de execução e variáveis que podem ter influenciado na diferença encontrada entre predição e na execução de testes experimentais, que devem ser consideradas e discutidas para que haja um banco de dados universal de fácil reprodução.

Ao mesmo tempo que considerar um alto número de parâmetros para o treinamento dos dados podem deixá-los viciados, ou muito treinados a um molde específico, considerar poucos fatores, ou deixar em aberto para diferentes interpretações, podem deixar a desejar, dificultando a evolução de pesquisas na mesma linha.

7.1 SUGESTÕES PARA TRABALHOS FUTUROS

Em trabalhos futuros, sugere-se:

- A reprodução tal qual das condições utilizadas no trabalho de Zhang *et al.* (2020) para a validação do modelo proposto no presente trabalho, o que não foi possível nesse trabalho;
- Fazer um banco de dados ampliado para condições usuais e práticas de nossa região, com materiais, insumos e equipamentos de uso comum e fácil acesso para garantir reprodutibilidade e possibilidade de uso da tecnologia;

8. REFERÊNCIAS BIBLIOGRÁFICAS

- ADEWUMI, A. A.; OWOLABI, T. O.; ALADE, I. O.; OLATUNJI, S. O. Estimation of physical, mechanical and hydrological properties of permeable concrete using computational intelligence approach. **Applied Soft Computing**, [s.l.], v. 42, p. 342-350, 2016.
- AHMED, F. B.; MITU, S. M.; BISWAS, R. K.; AHSAN, K. A.; MIM, S. M.; AHMED, S. Forecast flexural strength of pervious concrete by SVR. **Materials Today: Proceedings**, [s.l.], v. 45, part. 6, p. 5277-5284, 2021.
- ALTHOFF, D.; FILGUEIRAS, R.; RODRIGUES, L. N. Estimating small reservoir evaporation using machine learning models for the Brazilian Savannah. **Journal of Hydrologic Engineering**, [s.l.], v.25, 2020.
- ALTMAN, N. S. An introduction to Kernel and Nearest-Neighbor nonparametric regression. **The American Statistician**, [s.l.], v.46, n. 3, p.175-185, 1992.
- AMERICAN CONCRETE INSTITUTE (ACI) – ACI 552R-10: **Pervious Concrete**. 2010. Farmington Hills, 2010.
- ARABAMERI, A.; PRADHAN, B.; POURGHASEMI, H.R.; REZAEI, K.; KERLE, N. Spatial Modelling of Gully Erosion Using GIS and R Programing: A Comparison among Three Data Mining Algorithms. **Applied Sciences**, [s.l.], v. 8, n. 1369, 22p. 2018.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 5738: Concreto – Procedimento para moldagem e cura de corpos de prova**. Rio de Janeiro: ABNT, 2015. 9 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 5739: Concreto – Ensaio de compressão de corpos de prova cilíndricos**. Rio de Janeiro: ABNT, 2018. 9 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 9781: Peças de concreto para pavimentação – Especificação e método de ensaio**. Rio de Janeiro: ABNT, 2013. 21 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 9935: Agregados – Terminologia**. Rio de Janeiro: ABNT, 2011. 12 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 12142: Concreto – Determinação da resistência à tração na flexão de corpos de prova prismáticos**. Rio de Janeiro: ABNT, 2010. 5 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15805: Pisos elevados de placas de concreto – Requisitos e procedimentos**. Rio de Janeiro: ABNT, 2015. 21 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 16416: Pavimentos permeáveis de concreto – Requisitos e procedimentos**. Rio de Janeiro: ABNT, 2015. 25 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 16697: Cimento Portland – Requisitos**. Rio de Janeiro: ABNT, 2018. 12 p.

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 16889: Concreto – Determinação da consistência pelo abatimento do tronco de cone**. Rio de Janeiro: ABNT, 2020. 5 p.
- ASSOCIAÇÃO BRASILEIRA DE CIMENTO PORTLAND (ABCP). **Cimento**. São Paulo. Disponível em: < <https://abcp.org.br/cimento/>>. Acesso em: 13 nov. 2022.
- ASTERIS, P. G.; KOPIALIPOOR, 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.
- AS1012.14 – Methods of testing concrete: method 14: method for securing and testing cores from hardened concrete for compressive strength, **Materials Tests**, 1991.
- AS1012.9 – Methods of testing concrete, compressive strength tests – Concrete, mortar and grout specimens, **Author Sydney**, 2014.
- BATEZINI, R. **Estudo preliminar de concretos permeáveis como revestimento de pavimentos para área de veículos leves**. 2013. Dissertação (Mestrado em Engenharia) – Escola Politécnica da Universidade de São Paulo, São Paulo, São Paulo, 2013.
- BENEDETTI, J. K. On the nonparametric estimation of regression functions. **Journal of the Royal Statistical Society**, Series B (Methodological), [s.l.], v. 39, n. 2, p. 248–253, 1977.
- BOTTEON, L. M. – **Desenvolvimento e caracterização de concreto permeável para utilização em blocos intertravados para estacionamento**. 2017. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade Federal Fluminense, Niterói, 2017.
- BRAKE, N, A.; ALLAHADADI, H.; ADAM, F. Flexural strength and fracture size effects of pervious concrete. **Construction and Building Materials**, [s.l.], v. 113, p. 536-543, 2016.
- BREIMAN, L. Random forests. **Machine Learning**, [s.l.], v. 45, p.5-32, 2001.
- BROWN, M.; LEWIS, H.G.; GUNN, S.R. Linear spectral mixture models and support vector machines for remote sensing. **IEEE Transactions on geoscience and remote sensing**, v. 38, n. 5, p. 2346-2360. 2000.
- BUEHLMANN, P.; HOTHORN, T. Boosting algorithms: regularization, prediction and model fitting. **Statistical Science**, v.22, n.4, p. 477–505, 2007.
- BURDEN, F.; WINKLER D. Bayesian regularization of neural networks. **Artificial neural networks: Methods in Molecular Biology**, [s.l.], v. 458, p. 23–42, 2008.
- BURMAN, P. A comparative study of ordinary cross-validation, v-fold cross-validation and the learning-testing methods. **Biometrika**, [s.l.], v. 76, p. 503–514, 1989.
- CALLEGARI-JACQUES, S. M. **Bioestatística: princípios e aplicações**. 1. ed. Porto Alegre: Artemed, 2003. 264p. ISBN 978-85-3630-09-24.
- CANDIOTI, L. V.; ZAN, M. M. DE; CÁMARA, M. S.; GOICOECHEA, H. C. Experimental design and multiple response optimization. Using the desirability function in analytical methods development, **Talanta**, 2014.

- CASTRO, L.F.A.: **Estudo de traço de concreto permeável de cimento Portland**. 2015. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade de Santa Cruz do Sul, Santa Cruz do Sul, 2015.
- CHAABENE, W. B.; FLAH, M.; NEHDI, M. L. Machine learning prediction of mechanical properties of concrete: Critical review. **Construction and Building Materials**, [s.l.], v. 260, 2020.
- CHANDRAPPA, A. K.; BILIGIRI, K. P. Pervious concrete as a sustainable pavement material – Research findings and future prospects: A state-of-the-art review. **Construction and Building Materials**, [s.l.], v. 111, p. 262-274, 2016.
- CHEN, S.; ZHAO, Y.; BIE, Y. The prediction analysis of properties of recycled aggregate permeable concrete based on back-propagation neural network. **Journal of Cleaner Production**, [s.l.], v. 276, 2020.
- CHEN, X.; WANG, H.; NAJIM, H.; VENKITEELA, G.; HENCKEN, J. Evaluating engineering properties and environmental impact of pervious concrete with fly ash and slag. **Journal of Cleaner Production**, [s.l.], v. 237, n. 10, 2019.
- CHEUNG, J.; ROBERTS, L.; LIU, J. Admixtures and sustainability. **Cement and Concrete Research**, [s.l.], v. 114, p. 79-89, 2018.
- CJJ/T 135-2009 – **Standard, Chinese Technical Specifications for Pervious Concrete Pavement**, 2009.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, [s.l.], v.20, p.273-297, 1995.
- CUMMIS, D. J.; BELL, M. A. Integrating Everything: The Molecule Selection Toolkit, a System for Compound Prioritization in Drug Discovery. **American Chemical Society**, [s.l.], v.59, n. 15, p.6999-7010, 2016.
- DEBNATH, B.; SARKAR, P. P. Characterization of pervious concrete using over burnt brick as coarse aggregate. **Construction and Building Materials**, [s.l.], v. 242, 2020.
- DEGTYAREV, V. V. Machine learning models for predicting bond strength of deformed bars in concrete. **Structural Journal**, [s.l.], v.119, p.46-56, 2022.
- DEO, O.; NEITHALATH, N. Compressive behavior of pervious concretes and a quantification of the influence of random pore structure features. **Materials Science and Engineering: A**, [s.l.], v. 528, ed. 1, p. 402-412, 2010.
- DERRINGER, G.; SUICH, R. J. Simultaneous Optimization of Several Response Variables. **Journal of Quality Technology**, [s.l.], v. 12, p. 214-219, 1980.
- DUAN, J.; ASTERIS, P. G.; NGUYEN, H.; BUI, X-N.; MOAYEDI, H. A novel artificial intelligence technique to predict compressive strength of recycled aggregate concrete using ICA-XGBoost model. **Engineering with Computers**, [s.l.], v. 37, p. 3329-3346, 2021.
- DUAN, K.; CAO, S.; LI, J.; XU, C. Prediction of neutralization depth of RC bridges using machine learning methods. **Crystals**, [s.l.], v. 11 (2), 210, 2021.

- FAROOQ, F.; AHMED, W.; AKBAR, A.; ASLAM, F.; ALYOUSEF, R. Predictive modeling for sustainable high-performance concrete from industrial wastes: A comparison and optimization of models using ensemble learners. **Journal of Cleaner Production**, [s.l.], v. 292, 2021a.
- FAROOQ, F.; AMIN, M. N.; KHAN, K.; SADIQ, M. R.; JAVED, M. F.; ASLAM, F.; ALYOUSEF, R. A comparative study of random forest and genetic engineering programming for the prediction of compressive strength of high strength concrete (HSC). **Applied Sciences**, v. 10, n. 20, 2020.
- FAROOQ, F.; CZARNECKI, S.; NIEWIADOMSKI, P.; ASLAM, F.; ALABDULJABBAR, H.; OSTROWSKI, K. A.; SLIWA-WIECZOREK, K.; NOWOBILSKI, T.; MALAZDREWICZ, S. A comparative study for the prediction of the compressive strength of self-compacting concrete modified with fly ash. **Materials**, Basel, Switzerland, v. 14, 2021b.
- FONSECA, R. M. da C. Aprendizado de máquina para previsão de resistência à compressão de argamassa. 2021. Dissertação (Mestrado em modelagem e otimização) – Universidade Federal de Goiás, Catalão, 2021.
- FREUND, Y. Boosting a Weak Learning Algorithm by Majority. **Information and Computation**. [s.l.], v. 121, p. 256-285, 1995.
- FU, T. C.; YEIH, W.; CHANG, Y. J.; HUANG, R. The influence of aggregate size and binder material the properties of pervious concrete. **Advances in Materials Science and Engineering**, [s.l.], v. 2014, 17p., 2014.
- GAEDICKE, C.; MARINES, A.; MIANKODILA, F. A method for comparing cores and cast cylinders in virgin and recycled aggregate pervious concrete. **Construction and Building Materials**, [s.l.], v. 52, p. 494-503, 2014.
- GARCIA, J.; VILLAVICENCIO, G.; ALTIMIRAS, F.; CRAWFORD, B.; SOTO, R.; MINATOGAWA, V.; FRANCO, M.; MUÑOZ, D. M.; YEPES, V. Machine learning techniques applied to construction: A hybrid bibliometric analysis of advances and future directions. **Automation in Construction**, [s.l.], v. 142, 2022.
- GARCIA, J. A.; PEREIRA-FILHO, E. R. Desenvolvimento de um método de preparo de amostras para avaliação de matérias-primas de materiais escolares. **Química Nova**, v. 38, n.6, 2015.
- GHABOUSSI, J.; GARRETT, J. H. JR.; WU, X. Knowledge-based modeling of material behavior with Neural Networks. **Journal of Engineering Mechanics**, [s.l.], v. 117, 1991.
- GHAFOORI, N. Development of No-Fines Concrete Pavement Applications. **Journal of Transportation Engineering**, [s.l.], v. 121, n. 3, p. 283-288, 1995.
- GHOLAMPOUR, A.; GANDOMI, A. H.; OZBAKKALOGLU, T. New formulations for mechanical properties of recycled aggregate concrete using gene expression programming. **Construction and Building Materials**, [s.l.], v. 130, p. 122-145, 2017.
- GOETHALS, P. L.; CHO, B. R. Extending the desirability function to account for variability measures in univariate and multivariate response experiments. **Computers and Industrial Engineering**, v. 62, n.2, p. 457–468, 2012.

- HAN, T.; SIDDIQUE, A.; KHAYAT, K.; HUANG, J.; KUMAR, A. An ensemble machine learning approach for prediction and optimization of modulus of elasticity of recycled aggregate concrete. **Construction and Building Materials**, [s.l.], v. 244, 2020.
- HARRINGTON, E. C. JR. The Desirability Function. **Industrial Quality Control**, [s.l.], v. 21, p. 494-498, 1965.
- HASSAN, S. A.; KHAN, M. S. Climatic variability impact on river flow modeling of Chitral and Gilgit stations, Pakistan. **Modeling Earth Systems and Environment**, [s.l.], v. 8, p. 4295-4305, 2022.
- HÖLTZ, F. da C. **Uso de concreto permeável na drenagem urbana: análise da viabilidade técnica e do impacto ambiental**. 2011. Dissertação (Mestrado em Engenharia) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.
- HOSSEINALIZADEH, M.; KARIMINEJAD, N.; CHEN, W.; POURGHASEMI, H.R.; ALINEJAD, M.; BEHBAHANI, A.M.; TIEFENBACHER, J.P. Gully headcut susceptibility modeling using functional trees, naïve Bayes tree, and random forest models. **Geoderma**, [s.l.], v. 342, p. 1–11, 2019.
- HOUBORG, R.; MCCABE, M. F. A hybrid training approach for leaf area index estimation via Cubist and random forests machine-learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v. 135, p. 173-188, 2018.
- HUANG, B.; WU, H.; SHU, X.; BURDETTE, E. G. Laboratory evaluation of permeability and strength of polymer-modified pervious concrete. **Construction and Building Materials**, [s.l.], v. 24, p. 818-823, 2010.
- HUANG, J.; DUAN, T.; ZHANG, Y.; LIU, J.; ZHANG, J.; LEI, Y. Predicting the Permeability of Pervious Concrete Based on the Beetle Antennae Search Algorithm and Random Forest Model. **Advances in Civil Engineering**, [s.l.], v. 2020, 11p., 2020.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Estatísticas do século XX**. 2003. Disponível em <<https://ww2.ibge.gov.br/home/presidencia/noticias/29092003estatisticasecxxhtml.sht>>. Acesso em: 15/11/2021.
- IBRAHIM, A.; MAHMOUD, E.; YAMIN, M.; PATIBANDLA, V. C. Experimental study on Portland cement pervious concrete mechanical and hydrological properties. **Construction and Building Materials**, [s.l.], v. 50, p. 524-529, 2014.
- IZBICKI, R.; SANTOS, T. M. dos. **Aprendizagem de máquina: Uma abordagem estatística**, 1. ed. São Carlos: Livro eletrônico, 2020. 272 p. ISBN: 978-65-00-02410-4.
- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. An Introduction to Statistical Learning with Applications in R. [S.l.]: Springer, p. 426, 2017.
- JHA, A. K.; ADHIKARI, S.; THAPA, S.; KUMAR, A.; KUMAR, A.; MISHRA, S. Evaluation of Factors Affecting Compressive Strength of Concrete using Machine Learning. **Advanced**

- Computing and Communication Technologies for High Performance Applications (ACCTHPA)**, Cochin, p. 70-74, 2020.
- JIMMA, B. E.; RANGARAJU, P. R. Chemical admixtures dose optimization in pervious concrete paste selection – A statistical approach. **Construction and Building Materials**, [s.l.], v. 101, part. 1, p. 1047-1058, 2015.
- KEVERN, J.T.; HASELBACH, L.; SCHAEFER, V.R. Hot weather comparative heat balances in pervious concrete and impervious concrete pavement systems. **Journal of Heat Island Institute International**, [s.l.], v. 7, n. 2, p. 231-237, 2012.
- KEVERN, J., SCHAEFER, V., WANG, K., Temperature Behavior of Pervious Concrete Systems, **Transportation Research Record: Journal of the Transportation Research Board**, [s.l.], v. 2098, p. 94-101, 2009.
- KHALIL, A.; MCKEE, M.; KEMBLOWSKI, M.; ASEFA, T. Sparse Bayesian learning machine for real-time management of reservoir releases. **Water Resources Research**, [s.l.], v. 41, 15 p. 2005.
- KIA, A.; HONG, S.; CHEESEMAN, C. Clogging in permeable concrete: a review. **Journal of Environmental Management**, [s.l.], v. 193, p. 221-233, 2017.
- KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. New York: Springer, 2013, 600 p. ISBN 978-14-6146-84-86.
- KUHN, M. **Available Models. In: The caret Package**. 2019. Disponível em: <<https://topepo.github.io/caret/index.html>>. Acesso em: 30 ago. 2022.
- KUHN, M.; WESTON, S.; KEEFER, C.; COULTER, N. Cubist Models For Regression, 2012.
- KUMAR, A.; ARORA, H. C.; KUMAR, K.; MOHAMMED, M. A.; MAJUMDAR, A.; KHAMAKSORN, A.; THINNUKOOL, O. Prediction of FRCM–Concrete Bond Strength with Machine Learning Approach. **Sustainability**, v. 14, 25p. 2022.
- KURNAZ, T. F.; KAYA, Y. The comparison of the performance of ELM, BRNN, and SVM methods for the prediction of compression index of clays. **Arabian Journal of Geosciences**, [s.l.], v. 11, n. 770, 14 p., 2018.
- LACOSTE, M.; MINASNY, B.; MCBRATNEY, A.; MICHOT, D.; VIAUD, V.; WALTER, C. High resolution 3D mapping of soil organic carbon in a heterogeneous agricultural landscape. **Geoderma**, [s.l.], v. 213, p. 296-311, 2014.
- LAHMIRI, S.; BEKIROS, S. Intelligent forecasting with machine learning trading systems in chaotic intraday Bitcoin market. **Chaos, Solitons & Fractals**, [s.l.], v. 133, n. 21, 2020.
- LAMB, G. S. **Desenvolvimento e análise do desempenho de elementos de drenagem fabricados em concreto permeável**. 2014. Dissertação (Mestrado em Engenharia) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014.
- LE, B. A.; VU, V. H.; SEO, S. Y.; TRAN, B. V.; NGUYEN-SY, T.; LE, M. C.; VU, T. S. Predicting the Compressive Strength and the Effective Porosity of Pervious Concrete Using Machine Learning Methods. **KSCE Journal of Civil Engineering**, [s.l.], v. 26, p. 4664-4679, 2022.

- LIAN, C.; ZHUGE, Y.; BEECHAM, S. The relationship between porosity and strength for porous concrete. **Construction and Building Materials**, [s.l.], v. 25, p. 4294-4298, 2011.
- LIU, E.; TAN, K. H.; FWA, T. F. Effect of Mix Proportion on Strength and Permeability of Pervious Concrete for Use in Pavement. **Journal of the Eastern Asia Society for Transportation Studies**, v.10, 2013.
- LIU, R.; CHI, Y.; CHEN, S.; JIANG, Q.; MENG, X.; WU, K.; LI, S. Influence of Pore Structure Characteristics on the Mechanical and Durability Behavior of Pervious Concrete Material Based on Image Analysis. **International Journal of Concrete Structures and Materials**, [s.l.], v. 14, n. 29, 2020.
- MACKAY, D. J. C. **Bayesian methods for adaptive models**. 1992. Dissertation (Ph.D the Degree of Doctor of Philosophy) – California Institute of Technology, Pasadena, 1992.
- MAGUESVARI, M. U.; NARASIMHA, V, L, Studies on characterization of pervious concrete for pavement applications. **Procedia- Social and Behavior Sciences**, [s.l.], v. 104, p. 198-207, 2013.
- MAHESH, B. Machine Learning Algorithms – A Review. **International Journal of Science and Research**, [s.l.], v. 9, p. 381–386, 2020.
- MAHONEY, M. Introduction to Data Exploration and Analysis with R. 2019. Disponível em: <<https://bookdown.org/mikemahoney218/LectureBook/>>. Acesso em: 09 fev. 2023.
- MALAMI, S. I.; MUSA, A. A.; HARUNA, S. I.; ALIYU, U. U.; USMAN, A. G.; ABDURRAHMAN, M. I.; BASHIR, A.; ABBA, S. I. Implementation of soft-computing models for prediction of flexural strength of pervious concrete hybridized with rice husk ash and calcium carbide waste. **Modeling Earth Systems and Environment**, [s.l.], v. 8, p. 1933–1947, 2022.
- MAROLF, A.; NEITHALATH, N.; WEGNER, K.; SELL, E. Influence of aggregate size and gradation on the acoustic absorption of enhanced porosity concrete. **ACI Materials Journal**, [s.l.], v. 101 (1), 2004.
- MARTINS, M. E. G. Coeficiente de correlação amostral. **Revista de Ciência Elementar**, [s.l.], v. 2, n. 2, 4p. 2014.
- MONTEAGUDO, M. C.; BORGES, F.; CORDEIRO, M. N.; FAJIN, J. L. C.; MORELL, C.; RUIZ, R. M.; CARMENATE, Y. C.; DOMINGUEZ, E. R. Desirability-based methods of multiobjective optimization and ranking for global QSAR studies. Filtering safe and potent drug candidates from combinatorial libraries. **Journal of Combinatorial Chemistry**, [s.l.], v. 10, p. 897-913, 2008.
- MORGAN, D.; JACOBS, R. Opportunities and Challenges for Machine Learning in Materials Science. **Annual Review of Materials Research**, [s.l.], v. 50, p. 71-103, 2020.
- MOURA, J. M. B. M. de.; PINHEIRO, I. G.; AGUADO, A.; ROHDEN, A. B. Sustainable pervious concrete containing glass powder waste: Performance and modeling. **Journal of Cleaner Production**, [s.l.], v. 316, 2021.

- MULYONO, T.; ANISAH. Laboratory Experiment: Pervious Concrete for Permeable Pavement, Focus in Compressive Strength and Permeability. *International Conference on Sustainable Infrastructure: Earth and Environmental Science*, [s.l.], v. 366, 14p. 2019.
- MURPHY, K. P. **Machine learning: A probabilistic perspective**, 1. ed. Cambridge: MIT Press, 2012. 1104p. ISBN 978-0-262-01802-9.
- NARENDULA, S.; ADEPU, R. Evaluating the Properties of Pervious Concrete Pavement Towards Sustainable Environment Using Machine Learning Method. **Proceedings of the 2nd International Conference on IoT, Social, Mobile, Analytics & Cloud in Computational Vision & Bio-Engineering**, 2020.
- NEPTUNE, A. I.; PUTMAN, B. J. Effect of Aggregate Size and Gradation on Pervious Concrete Mixtures. **ACI Materials Journal**, [s.l.], v. 107, p. 625-631, 2010.
- NGUYEN, D. H.; SEBAIBI, N.; BOUTOUIL, M.; LELEYTER, L.; BARAUD, F. A modified method for the design of pervious concrete mix. **Construction and Building Materials**, [s.l.], v. 73, p. 271-282, 2014.
- NGUYEN, H.; BUI, X. N.; TRAN, Q. H.; MAI, N. L. A new soft computing model for estimating and controlling blast-produced ground vibration based on Hierarchical K-means clustering and Cubist algorithms. *Applied Soft Computing*. [s.l.], v. 77, p. 376-386, 2019.
- NOBLE, W. S. What is a support vector machine? **Nature Biotechnology**, [s.l.], v. 24, p. 1565-1567, 2006.
- OLIVEIRA, L. C. B. **Análise de permeabilidade e da colmatação em concretos permeáveis com agregado reciclado de concreto**. 2017. Dissertação (Mestrado em Sistemas de Infraestrutura Urbana) – Centro de Ciências Exatas, Ambientais e Tecnológicas, Pontifícia Universidade Católica de Campinas, Campinas, 2017.
- OZBEK, A. S. A.; WEERHEIJM, J.; SCHLANGEN, E.; BREUGEL, K. V. Investigating porous concrete with improved strength: Testing at different scales. **Construction and Building Materials**, [s.l.], v. 41, p. 480-490, 2013.
- 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.
- PAREEK, K.; HONG, Y. M. Prediction of Permeability and Compressive strength for Pervious Concrete. **IOP Conf. Series: Materials Science and Engineering**, [s.l.], v. 812, 2020.
- PARK, S. B.; LEE, B. J.; LEE, J.; JANG, Y. A study on the seawater purification characteristics of water-permeable concrete using recycled aggregate. **Resources, Conservation and Recycling**, [s.l.], v. 54, p. 658-665, 2010.
- PARK, S. B.; TIA, M. An experimental study on the water-purification properties of porous concrete. **Cement and Concrete Research**, [s.l.], v. 34, n. 2, p. 177-184, 2004.

- PEREIRA, L. de O.; SILVA, A. E. P.; NEGRI, R. G.; SANT'ANNA, S. J. S.; DUTRA, L. V.; FREITAS, C. da C.; ERTHAL, G. J. Análise comparativa dos métodos de classificação SVM e Maxver-ICM Polarimétrico em imagem de radar ALOS PALSAR. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, INPE, 2011, p.8223.
- PIMENTA, C. D.; SILVA, M. B.; SALOMON, V. A. P.; PENTEADO, R. B.; GOMES, F. M. Aplicação das metodologias Desirability e Simplex para otimização das propriedades mecânicas em arames de aço temperados. **Production**, [s.l.], v. 25, n. 3, p. 598-610, 2015
- QUINLAN, J. R. Combining instance-based and model-based learning. **Proceedings of the Tenth International Conference on Machine Learning**, [s.l.], p. 236-343, 1993.
- QUINLAN, J. R. Improved use of continuous attributes in C4.5. **Journal of Artificial Intelligence Research**, [s.l.], v. 4, p. 77-90, 1996.
- QUINLAN, J. R. Learning with continuous classes. **Proceedings of Australian Joint Conference on Artificial Intelligence**, Hobart, p. 343-348, 1992.
- RDocumentation. **R packages on CRAN and Bioconductor**, 2022. Disponível em: <<https://www.rdocumentation.org/>>. Acesso em: 30 dez. 2022.
- RODRÍGUEZ, A. S.; CASTILLO, Y. P.; SCHURER, S. C.; NICOLOTTI, O.; MANGIATORDI, G. F.; BORGES, F.; CORDEIRO, M. N. D. S.; TEJERA, E.; FRANCO, J. L.; MONTEAGUDO, M. C. From flamingo dance to (desirable) drug discovery: a nature-inspired approach. **Drug Discovery Today**, [s.l.], v. 22, p. 1489-1502, 2017.
- SALIMBAHRAMI, S. R.; SHAKERI, R. Experimental investigation and comparative machine-learning prediction of compressive strength of recycled aggregate concrete. **Soft Computing**, [s.l.], v. 25, p. 919-932, 2021.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal Research and Development**, [s.l.], v. 3 n.3, p. 210-229, 1959.
- SANKET, S.; SARITA, S.; TARANJEET, K. Mechanical properties of pervious concrete. **International Conference on Advances in Civil Engineering**, 2012; ACEE, India.
- SANTOS, H. G. dos. **Comparação da performance de algoritmos de machine learning para a análise preditiva em saúde pública e medicina**. 2018. Tese (Doutorado em Ciências) – Faculdade de Saúde Pública da Universidade de São Paulo, São Paulo, 2018.
- SHAPIRE, R. E. A brief introduction to boosting. **Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence**, 1999.
- SHAPIRE, R. E. The strength of weak learnability. **Machine Learning**, [s.l.], v.5, p. 197-227, 1990.
- SHARIATI, M.; MAFIPOUR, M. S.; GHAHREMANI, B.; AZARHOMAYUN, F.; AHMADI, M.; TRUNG, N. T.; SHARIATI, A. A novel hybrid extreme learning machine–grey wolf optimizer (ELM-GWO) model to predict compressive strength of concrete with partial replacements for cement. **Engineering with Computers**, [s.l.], v. 38, p. 757–779, 2022.

- SHERWANI, A. F. H.; FARAJ, R.; YOUNIS, K. H.; DARAEI, A. Strength, abrasion resistance and permeability of artificial fly-ash aggregate pervious concrete. **Case Studies in Construction Materials**, [s.l.], v. 14, 2021.
- SHIRGIR, B.; MAMDOOHI, A. R.; HASSANI, A. Prediction of Pervious Concrete Permeability and Compressive Strength Using Artificial Neural Networks. **International Journal of Transportation Engineering**, [s.l.], v.2, n. 4, 2015.
- SOETEWEEY, A. Descriptive statistics in R. In: **Stats and R**, 2020. Disponível em: <<https://statsandr.com/blog/descriptive-statistics-in-r/>>. Acesso em: 09 fev. 2023.
- SONEBI, M.; BASSUONI, M. T Investigating the effect of mixture design parameters on pervious concrete by statistical modelling, **Construction and Building Materials**, v. 38, p. 147-154, 2013.
- SONEBI, M.; BASSUONI, M.; YAHIA, A. Pervious concrete: mix design, properties and applications. **RILEM Technical Letters**, [s.l.], v.1, p. 109– 115, 2016.
- STONE, C. J. Consistent nonparametric regression. **The annals of statistics**, [s.l.], v. 1, p. 109– 115, 2016.
- SUN, J.; ZHANG, J.; GU, Y.; HUANG, Y.; SUN, Y.; MA, G. Prediction of permeability and unconfined compressive strength of pervious concrete using evolved support vector regression. **Construction and Building Materials**, [s.l.], v. 207, p. 440-449, 2019.
- SUN, Z.; LIN, X.; VOLLPRACHT, A. Pervious concrete made of alkali activated slag and geopolymers. **Construction and Building Materials**, [s.l.], v. 189, p. 797-803, 2018.
- TENNIS, P. D.; LEMING, M. L.; AKERS, D. J. Pervious Concrete Pavements. **Portland Cement Association**, Skokie, 36p. 2004.
- TIPPING, M. E. Bayesian inference: An introduction to principles and practice in machine learning. **Advanced Lectures on Machine Learning**, Cambridge. U.K, p. 41-62, 2006.
- TIPPING, M. E. The Relevance Vector Machine. **Microsoft Research**, Cambridge. U.K, p. 652-658, 2000.
- TONG, S.; KOLLER, D. Active learning for structure in Bayesian networks. **International Joint Conference on Artificial Intelligence**, [s.l.], v. 17, p. 863–869, 2001.
- TORRES, A.; HU, J.; RAMOS, A. The effect of the cementitious paste thickness on the performance of pervious concrete. **Construction and Building Materials**, [s.l.], v. 95, p. 850-859, 2015.
- TUCCI, C. E. M. **Inundações urbanas**. 1 ed. Porto Alegre: ABRH/RHAMA, 2007. 352p. ISBN: 978-85-8868-621-2.
- TUCCI, C. E. M. Parâmetros dos hidrogramas unitários para bacias urbanas brasileiras. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 8, n. 2, p. 195-199, 2003.
- VAPNIK, V. N. **The Nature of Statistical Learning Theory**. 1ed. New York: Springer, 1995. 334p.
- WANG, H.; LI, H.; LIANG, X.; ZHOU, H.; XIE, N.; DAI, Z. Investigation on the mechanical properties and environmental impacts of pervious concrete containing fly ash based on the cement-aggregate ratio. **Construction and Building Materials**, [s.l.], v. 202, p. 387-395, 2019.

- YAHIA, A.; KABAGIRE, K. D. New approach to proportion pervious concrete. **Construction and Building Materials**, [s.l.], v. 62, p. 38-46, 2014.
- YANG J., DENG S., XU H., ZHAO Y., NIE C., HE Y. Investigation and practical application of silica nanoparticles composite underwater repairing materials. **Energies**, [s.l.], v. 14. p. 202, 2021.
- YANG, J.; JIANG, G. Experimental study on properties of pervious concrete pavement materials. **Cement and Concrete Research**, [s.l.], v. 33, p. 381-386, 2003.
- YEH, I. C. Modeling of strength of high-performance concrete using artificial neural networks. **Cement and Concrete Research**, [s.l.], v. 28, p. 1797- 1808, 1998.
- YU, H.; XIE, T.; PASZCZYNSKI, S.; WILAMOWSKI, B. Advantages of Radial Basis Function Networks for Dynamic System Design. *IEEE Transactions on Industrial Electronics*, [s.l.], v. 58, n. 12, p. 5438-5450, 2011.
- YU, F.; SUN, D.; WANG, J.; HU, M. Influence of aggregate size on compressive strength of pervious concrete. **Construction and Building Materials**, [s.l.], v. 209, p. 463-475, 2019.
- ZHANG, J.; HUANG, Y.; WANG, Y.; MA, G.; SUN, J.; NENER, B. A metaheuristic-optimized multi-output model for predicting multiple properties of pervious concrete. **Construction and Building Materials**, [s.l.], v. 229, 2020.
- ZHANG, Y.; LI, H.; ABDELHADY, A.; YANG, J. Comparative laboratory measurement of pervious concrete permeability using constant-head and falling-head permeameter methods. **Construction and Building Materials**, [s.l.], v. 263, 2020b.
- ZHENG, L.; CHENG, H.; HUO, L.; SONG, G. Monitor concrete moisture level using percussion and machine learning. **Construction and Building Materials**, [s.l.], v. 229, 2019.
- ZHONG, R.; LENG, Z.; POON, C. S. Research and application of pervious concrete as a sustainable pavement material: A state-of-the-art and state-of-the-practice review. **Construction and Building Materials**, [s.l.], v. 183, p. 544-553, 2018.
- ZHONG, R.; WILLE, K. Compression response of normal and high strength pervious concrete. **Construction and Building Materials**, [s.l.], v. 109, p. 177-187, 2016.
- ZHOU, J.; LI, E.; WEI, H.; LI, C.; QIAO, Q.; ARMAGHANI, D. J. Random Forests and Cubist Algorithms for Predicting Shear Strengths of Rockfill Materials. [s.l.], **Applied Sciences**, v. 8, 16p. 2019.

ANEXO A – BANCO DE DADOS (ZHANG *et al.*, 2020)

QUADRO A – Bando de dados concreto permeável (continua).

| AC | DIAM | AGCIM | COMP | PERM |
|------|------|-------|-------|------|
| 0,25 | 3,50 | 2,50 | 15,30 | 0,62 |
| 0,25 | 3,50 | 3,00 | 14,20 | 0,89 |
| 0,25 | 3,50 | 3,50 | 13,10 | 1,42 |
| 0,25 | 3,50 | 4,00 | 11,80 | 1,93 |
| 0,25 | 3,50 | 4,50 | 10,70 | 2,31 |
| 0,30 | 3,50 | 2,50 | 16,20 | 0,97 |
| 0,30 | 3,50 | 3,00 | 15,10 | 1,08 |
| 0,30 | 3,50 | 3,50 | 13,90 | 1,86 |
| 0,30 | 3,50 | 4,00 | 12,60 | 2,45 |
| 0,30 | 3,50 | 4,50 | 11,60 | 2,75 |
| 0,35 | 3,50 | 2,50 | 14,40 | 0,63 |
| 0,35 | 3,50 | 3,00 | 13,40 | 0,82 |
| 0,35 | 3,50 | 3,50 | 12,10 | 1,38 |
| 0,35 | 3,50 | 4,00 | 10,80 | 1,92 |
| 0,35 | 3,50 | 4,50 | 9,90 | 2,31 |
| 0,40 | 3,50 | 2,50 | 12,50 | 0,44 |
| 0,40 | 3,50 | 3,00 | 11,40 | 0,67 |
| 0,40 | 3,50 | 3,50 | 10,20 | 1,13 |
| 0,40 | 3,50 | 4,00 | 8,70 | 1,61 |
| 0,40 | 3,50 | 4,50 | 7,70 | 1,98 |
| 0,45 | 3,50 | 2,50 | 10,70 | 0,12 |
| 0,45 | 3,50 | 3,00 | 9,60 | 0,38 |
| 0,45 | 3,50 | 3,50 | 8,50 | 0,71 |
| 0,45 | 3,50 | 4,00 | 6,90 | 1,23 |
| 0,45 | 3,50 | 4,50 | 6,10 | 1,58 |
| 0,50 | 3,50 | 2,50 | 9,50 | 0,10 |
| 0,50 | 3,50 | 3,00 | 8,10 | 0,20 |
| 0,50 | 3,50 | 3,50 | 6,20 | 0,50 |
| 0,50 | 3,50 | 4,00 | 5,50 | 1,10 |
| 0,50 | 3,50 | 4,50 | 5,00 | 1,21 |
| 0,25 | 7,50 | 2,50 | 29,50 | 1,19 |
| 0,25 | 7,50 | 3,00 | 28,40 | 1,36 |
| 0,25 | 7,50 | 3,50 | 27,20 | 2,06 |
| 0,25 | 7,50 | 4,00 | 25,90 | 2,84 |
| 0,25 | 7,50 | 4,50 | 24,80 | 3,08 |
| 0,30 | 7,50 | 2,50 | 30,00 | 1,63 |
| 0,30 | 7,50 | 3,00 | 28,80 | 1,82 |
| 0,30 | 7,50 | 3,50 | 27,90 | 2,61 |
| 0,30 | 7,50 | 4,00 | 26,50 | 3,39 |
| 0,30 | 7,50 | 4,50 | 25,60 | 3,64 |

QUADRO A – Bando de dados concreto permeável (continuação).

| AC | DIAM | AGCIM | COMP | PERM |
|------|-------|-------|-------|------|
| 0,35 | 7,50 | 2,50 | 27,10 | 0,98 |
| 0,35 | 7,50 | 3,00 | 25,80 | 1,16 |
| 0,35 | 7,50 | 3,50 | 25,00 | 1,88 |
| 0,35 | 7,50 | 4,00 | 23,90 | 2,67 |
| 0,35 | 7,50 | 4,50 | 22,80 | 2,88 |
| 0,40 | 7,50 | 2,50 | 25,50 | 0,68 |
| 0,40 | 7,50 | 3,00 | 24,20 | 0,89 |
| 0,40 | 7,50 | 3,50 | 23,30 | 1,51 |
| 0,40 | 7,50 | 4,00 | 22,20 | 2,16 |
| 0,40 | 7,50 | 4,50 | 21,10 | 2,40 |
| 0,45 | 7,50 | 2,50 | 22,80 | 0,29 |
| 0,45 | 7,50 | 3,00 | 21,60 | 0,52 |
| 0,45 | 7,50 | 3,50 | 20,60 | 1,02 |
| 0,45 | 7,50 | 4,00 | 19,50 | 1,54 |
| 0,45 | 7,50 | 4,50 | 18,40 | 1,85 |
| 0,50 | 7,50 | 2,50 | 20,10 | 0,19 |
| 0,50 | 7,50 | 3,00 | 19,50 | 0,38 |
| 0,50 | 7,50 | 3,50 | 18,00 | 0,95 |
| 0,50 | 7,50 | 4,00 | 16,90 | 1,13 |
| 0,50 | 7,50 | 4,50 | 16,10 | 1,35 |
| 0,25 | 13,00 | 2,50 | 19,40 | 2,26 |
| 0,25 | 13,00 | 3,00 | 18,40 | 2,41 |
| 0,25 | 13,00 | 3,50 | 17,10 | 3,00 |
| 0,25 | 13,00 | 4,00 | 15,70 | 3,46 |
| 0,25 | 13,00 | 4,50 | 14,60 | 3,83 |
| 0,30 | 13,00 | 2,50 | 20,10 | 2,43 |
| 0,30 | 13,00 | 3,00 | 19,40 | 2,59 |
| 0,30 | 13,00 | 3,50 | 17,80 | 3,17 |
| 0,30 | 13,00 | 4,00 | 16,40 | 3,74 |
| 0,30 | 13,00 | 4,50 | 15,30 | 4,07 |
| 0,35 | 13,00 | 2,50 | 17,10 | 2,12 |
| 0,35 | 13,00 | 3,00 | 16,10 | 2,28 |
| 0,35 | 13,00 | 3,50 | 14,70 | 2,87 |
| 0,35 | 13,00 | 4,00 | 13,50 | 3,35 |
| 0,35 | 13,00 | 4,50 | 12,40 | 3,72 |
| 0,40 | 13,00 | 2,50 | 15,20 | 1,59 |
| 0,40 | 13,00 | 3,00 | 14,20 | 1,72 |
| 0,40 | 13,00 | 3,50 | 13,00 | 2,38 |
| 0,40 | 13,00 | 4,00 | 11,60 | 2,97 |
| 0,40 | 13,00 | 4,50 | 10,60 | 3,34 |
| 0,45 | 13,00 | 2,50 | 12,90 | 1,08 |
| 0,45 | 13,00 | 3,00 | 11,90 | 1,22 |
| 0,45 | 13,00 | 3,50 | 10,50 | 1,94 |

QUADRO A – Bando de dados concreto permeável (fim).

| AC | DIAM | AGCIM | COMP | PERM |
|------|-------|-------|-------|------|
| 0,45 | 13,00 | 4,00 | 9,20 | 2,56 |
| 0,45 | 13,00 | 4,50 | 8,10 | 2,90 |
| 0,50 | 13,00 | 2,50 | 10,50 | 0,95 |
| 0,50 | 13,00 | 3,00 | 10,00 | 1,01 |
| 0,50 | 13,00 | 3,50 | 9,10 | 1,35 |
| 0,50 | 13,00 | 4,00 | 7,50 | 2,10 |
| 0,50 | 13,00 | 4,50 | 6,90 | 2,46 |

Fonte: Zhang *et al.* (2020).