



**PREVISÃO DO COMPORTAMENTO DO CIMENTO
PORTLAND CPIV POR MEIO DO USO DE TÉCNICAS DE
MACHINE LEARNING COM DIFERENTES BANCOS DE
DADOS**

LUCAS DE PAULA VASQUES

DISSERTAÇÃO DE MESTRADO

**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA**

BRASÍLIA/DF, JULHO DE 2023

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ESTRUTURAS E
CONSTRUÇÃO CIVIL

PREVISÃO DO COMPORTAMENTO DO CIMENTO
PORTLAND CPIV POR MEIO DO USO DE TÉCNICAS DE
MACHINE LEARNING COM DIFERENTES BANCOS DE
DADOS

LUCAS DE PAULA VASQUES

ORIENTADOR: JOÃO HENRIQUE DA SILVA RÊGO
COORIENTADOR: FRANCISCO EVANGELISTA JUNIOR

DISSERTAÇÃO DE MESTRADO EM ESTRUTURAS E
CONSTRUÇÃO CIVIL

BRASÍLIA / DF: JULHO / 2023

PREVISÃO DO COMPORTAMENTO DO CIMENTO PORTLAND CPIV POR MEIO DO USO DE TÉCNICAS DE MACHINE LEARNING COM DIFERENTES BANCOS DE DADOS

LUCAS DE PAULA VASQUES

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

APROVADA POR:

JOÃO HENRIQUE DA SILVA RÊGO, D. Sc. (ENC/UnB)
(ORIENTADOR)

FRANCISCO EVANGELISTA JUNIOR, D. Sc. (ENC/UnB)
(COORIENTADOR)

GREGÓRIO LUÍS SILVA ARAÚJO, D. SC. (ENC/UNB)
(EXAMINADOR INTERNO)

ANDRIELLI MORAIS DE OLIVEIRA, D. SC. (ECAA/UFG)
(EXAMINADOR EXTERNO)

DATA: BRASÍLIA/DF, 25 de JULHO de 2023.

FICHA CATALOGRÁFICA

VASQUES, LUCAS DE PAULA

Previsão do comportamento do cimento Portland CPIV por meio do uso de técnicas de Machine Learning com diferentes bancos de dados [Distrito Federal] 2023

xiii, 113 p., 297 mm (ENC/FT/UnB, Mestre, Estruturas e Construção Civil, 2023)

Dissertação de Mestrado - Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

1. Machine Learning

2. Cimento Pozolânico

3. Argila Calcinada

4. Resistência à compressão

5. Artificial Neural Networks

I. UnB/FT/Engenharia Civil

II. Título (Mestre)

REFERÊNCIA BIBLIOGRÁFICA

VASQUES, L.P. (2023). Previsão do comportamento do cimento Portland CPIV por meio do uso de técnicas de Machine Learning com diferentes bancos de dados. Dissertação de Mestrado em Estruturas e Construção Civil, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 113 p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Lucas de Paula Vasques

TÍTULO: Previsão do comportamento do cimento Portland CPIV por meio do uso de técnicas de Machine Learning com diferentes bancos de dados.

GRAU / ANO: Mestre / 2023

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

Lucas de Paula Vasques

Residencial Interlagos, conj. J casa 9 – Jardim Botânico

71680-375 – Brasília/DF – Brasil

Email: vasqueslucas7@gmail.com

Dedico esse trabalho primeiramente a Deus, a minha família e a todos meus amigos e colegas que me apoiaram nesse tempo.

AGRADECIMENTOS

Agradeço primeiramente a Deus, pelo seu amor, sua graça e justiça que me sustentam a cada dia, a Ele toda a glória.

A meus pais, que me deram todo suporte e garantiram que chegasse aonde estou hoje. Ao meu pai, Walter, que me ensinou a nunca parar de estudar. À minha mãe, Paula, que me ensinou persistência e sempre me apoiou. À minha amada irmã Letícia, que foi companhia em todos esses anos e sempre me auxiliou quando necessário.

Ao meu orientador, professor João Henrique, por toda a paciência, conhecimento transmitido e orientação durante toda minha caminhada acadêmica.

Aos membros da banca, por se disporem a avaliar esse trabalho, pelas contribuições feitas e colaboração no aperfeiçoamento desta pesquisa.

Aos meus colegas de PECC, Jéssica Chaves, Vitor Pereira, Divino Gabriel e Yuri Sotero, por todo apoio e contribuições feitas desde meu início de caminhada no PECC. Um agradecimento especial também à querida professora Eugênia que mesmo à distância sempre forneceu grande apoio e motivação.

Aos meus amigos, que me apoiaram e me acompanharam em momentos de alegria e tristeza durante essa jornada. Um agradecimento especial à Carolina e ao Luiz Azambuja, por garantirem que eu conseguiria finalizar essa empreitada.

À Coordenação de aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Fundação Universidade de Brasília (FUB) e ao Decanato de Pós-Graduação (DPG) da UnB que ajudaram a financiar essa pesquisa.

Agradeço a UnB, pelas oportunidades que recebi nesse local, pelas experiências vividas e pelo conhecimento adquirido. E a todos meus colegas que ingressaram ao PECC juntamente comigo.

A todos os envolvidos diretamente ou não em todo esse processo, que desejaram o meu melhor e o sucesso de minha pesquisa.

"Do or do not, there is no try"

RESUMO

PREVISÃO DO COMPORTAMENTO DO CIMENTO PORTLAND CPIV POR MEIO DO USO DE TÉCNICAS DE MACHINE LEARNING COM DIFERENTES BANCOS DE DADOS

Autor: Lucas de Paula Vasques

Orientador: Prof. Dr. João Henrique da Silva Rêgo

Coorientador: Prof. Dr. Francisco Evangelista Júnior

Programa de Pós-graduação em Estruturas e Construção Civil

Brasília, julho de 2023.

O uso de cimentos pozolânicos tem crescido no meio da construção civil, de forma que mais estudos são necessários a fim de compreender suas propriedades. As técnicas de *Machine Learning* (ML) têm sido utilizadas em pesquisas recentes para análise de bancos de dados de propriedades de materiais como concretos e cimentos Portland. Notou-se que há uma ausência na literatura de trabalhos analisando a previsão da resistência à compressão de cimentos pozolânicos produzidos por uma única fábrica, ainda mais com o uso *inputs* de mais fácil obtenção. Portanto, neste trabalho foram utilizadas técnicas de *Artificial Neural Networks* com o objetivo de prever a resistência à compressão de cimentos contendo argila calcinada em sua composição. Foram utilizados dados de caracterização físico-química (como teores de óxidos e de compostos principais) do cimento de uma única indústria para a montagem de 5 bancos de dados, variando nos tipos de *inputs* adotados. Cada banco de dados foi utilizado para treinamento de um algoritmo diferente que posteriormente teve seu desempenho analisado por meio de indicadores de qualidade como R^2 , RMSE e MAPE. Dois dos algoritmos se destacaram entre os demais, um utilizando teores de óxidos (A1) e outro com teores de compostos principais (B2), sendo o primeiro mais eficiente nas previsões que o segundo. Foram apresentados para A1 e B2, respectivamente, valores de MAPE (2,36% e 3,12%), RMSE (1,204 e 1,513 MPa) e erro absoluto médio (0,999 e 1,300 MPa) considerados eficientes de acordo com a literatura existente, apesar de valores de R^2 (0,50 e 0,51). Por meio dos resultados obtidos foi possível efetuar previsões consideravelmente confiáveis (com baixo erros relativos e absolutos) da resistência à compressão aos 28 dias do cimento pozolânico. Tal fato faz dos modelos produzidos alternativas promissoras para a avaliação dessa propriedade em futuras pesquisas.

Palavras-chave: *Machine Learning*; Cimento pozolânico; Argila calcinada; Resistência à compressão; Artificial Neural Networks.

ABSTRACT

PREDICTION OF THE BEHAVIOR OF PORTLAND CPIV CEMENT THROUGH THE USE OF MACHINE LEARNING TECHNIQUES WITH DIFFERENT DATABASES

Author: Lucas de Paula Vasques

Supervisor: Prof. Dr. João Henrique da Silva Rêgo

Co-Supervisor: Prof. Dr. Francisco Evangelista Júnior

Programa de Pós-graduação em Estruturas e Construção Civil

Brasília, July of 2023.

The use of pozzolanic cement has grown in the field of civil construction, so more studies are needed to understand their properties. Machine Learning (ML) techniques have been used in recent research to analyze databases of properties of materials such as concrete and Portland cement. It was noted that there is an absence in the literature of studies analyzing the prediction of compressive strength of pozzolanic cement produced by a single factory, even more so with the use of easier inputs. Therefore, in this study, Artificial Neural Networks techniques were used to predict the compressive strength of cement containing calcined clay in their composition. Physical-chemical characterization data (such as oxide and main compound contents) of cement from a single industry were used to assemble 5 databases, varying in the types of inputs adopted. Each database was used to train a different algorithm that later had its performance analyzed using quality indicators such as R^2 , RMSE, and MAPE. Two of the algorithms stood out among the others, one using oxide contents (A1) and the other with principal compound contents (B2), the first being more efficient in forecasting than the second. For A1 and B2, respectively, values of MAPE (2.36% and 3.12%), RMSE (1.204 and 1.513 MPa) and mean absolute error (0.999 and 1.300 MPa) were considered efficient according to the existing literature, with R^2 values of 0.50 and 0.51. Through the results obtained, it was possible to make considerably reliable predictions (with low relative and absolute errors) of the compressive strength at 28 days of the pozzolanic cement. This fact makes the models produce promising alternatives for the evaluation of this property in future research.

Keywords: Machine Learning; Pozzolanic cement; Calcined clay; Compressive strength; Artificial Neural Networks.

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	IMPORTÂNCIA DO TEMA.....	1
1.2	MOTIVAÇÃO DA PESQUISA	3
1.3	OBJETIVOS	4
1.3.1	Objetivo Geral.....	4
1.3.2	Objetivos Específicos.....	4
1.4	Estrutura do Trabalho.....	5
2	REVISÃO DA LITERATURA	6
2.1	CIMENTO PORTLAND	6
2.1.1	Composição Química do Cimento Portland.....	7
2.1.2	Categorias de Cimento Portland – NBR 16697 (ABNT, 2018).....	10
2.2	COMPORTAMENTO DE CIMENTOS POZOLÂNICOS (CPIV)	14
2.3	MACHINE LEARNING (ML).....	24
2.3.1	Artificial Neural Networks (ANN)	25
2.3.2	Decision Trees (DT).....	26
2.3.3	Random Forest (RF).....	28
2.3.4	Aplicações de Machine Learning em Materiais Cimentícios.....	28
3	METODOLOGIA	38
3.1	Etapa 01- Tratamento dos Dados Fornecidos e Montagem de bancos de dados	39
3.1.1	Tratamento dos Dados Fornecidos.....	39
3.1.2	Montagem dos Bancos de Dados	42
3.2	Etapa 02 – Treinamento e Teste dos Algoritmos	47
3.2.1	Treinamento e Teste dos Algoritmos	48
3.2.2	Comparação de Desempenho.....	49
3.3	Etapa 03 – Comparação de Resultados entre Modelos “A” e “B”	50
4	RESULTADOS	51
4.1	Etapa 01 – Tratamento dos Dados e Montagem dos Bancos de Dados	51
4.1.1	Tratamento dos Dados Fornecidos.....	51
4.1.2	Análise do Banco de Dados Geral e Parâmetros Disponíveis.....	52
4.1.3	Montagem dos Bancos de Dados Tipo A.....	54
4.1.4	Montagem dos Bancos de Dados Tipo B	55
4.2	Etapa 02 – Treinamento e Teste dos Algoritmos	58
4.2.1	Algoritmos tipo A	59
4.2.2	Algoritmos Tipo B	69
4.3	Etapa 03 - Comparação entre Modelos de Previsão da Resistência do CPIV.....	80

4.3.1	Análise do Modelo A1	83
4.3.2	Análise do Modelo B2	86
4.3.3	Análise do Equilíbrio químico	87
4.3.4	Avaliação do Algoritmo mais Adequado	89
5	CONCLUSÕES	91
5.1	Recomendações para Pesquisas Futuras	93
REFERÊNCIAS		95
APÊNDICE A – BASE DE DADOS GERAL		102

LISTA DE TABELAS

Tabela 2.1 Composição das Classes de CP segundo a NBR 16697 (ABNT, 2018)	11
Tabela 2.2 - Limites Normativos segundo a NBR 16697/2018 para o CPIV (fonte: autor)	12
Tabela 2.3 - Modelos de ML propostos na Literatura para previsão de resistência à compressão aos 28 dias de cimentos Portland	33
Tabela 3.1 - Inputs nos bancos de dados tipo A.....	44
Tabela 3.2 - Inputs dos bancos de dados tipo B.....	46
Tabela 3.3 - Hiperparâmetros adotados para os algoritmos	48
Tabela 4.1 - Exemplos de Conjuntos da BDG	51
Tabela 4.2 - Parâmetros da BDG	54
Tabela 4.3 - Exemplos de Conjuntos do Banco de Dados A1	55
Tabela 4.4 – Exemplos de adequação da Composição CPIV para Composição Cimento Portland Comum.....	56
Tabela 4.5 - Exemplos de conversão de dados para formação dos bancos de dados tipo B	57
Tabela 4.6 - Exemplos de Conjuntos do Banco de Dados Tipo B	58
Tabela 4.7 - Parâmetros do Algoritmo A1 Testado	62
Tabela 4.8 - Parâmetros do Algoritmo A2 Testado	66
Tabela 4.9 – Comparação de Parâmetros dos Algoritmos Tipo A.....	68
Tabela 4.10 - Parâmetros do Algoritmo B1 Testado.....	71
Tabela 4.11 - Parâmetros do Algoritmo B2 Testado.....	74
Tabela 4.12 - Parâmetros do Algoritmo B3 Testado.....	78
Tabela 4.13 – Comparação de Parâmetros dos Algoritmos Tipo B.....	79
Tabela 4.14 - Parâmetros de Qualidade dos Modelos A1 e B2.....	81
Tabela 4.15 - Parâmetros da BDG utilizados nos algoritmos de tipo A	84
Tabela 4.16 - Influência dos teores dos parâmetros na composição do CPIV	87

LISTA DE FIGURAS

Figura 1.1 - Projeção da Produção de Cimento no Brasil para cenários de alta e baixa demanda do material (VISEDIO e PECCHIO, 2019)	1
Figura 2.1 - Evolução da resistência à compressão das argamassas A15, A30, A45 e A60 (LINS, 2017)	18
Figura 2.2 - Índice de Desempenho das misturas contendo 25% de substituição.....	19
Figura 2.3 - Tempos de início e fim de pega e relação a/c para os diferentes teores de AC incorporadas (AMER e EL-HOSEN, 2017)	21
Figura 2.4 - Índice de desempenho na resistência à compressão, em relação à substituições equivalentes de fíler silícico (ANTONI et al., 2012)	22
Figura 2.5 - Rede Neural multicamada (MUELLER, KUSNE, RAMPRASAD; 2016).....	25
Figura 2.6 - Rede Neural – Perceptron (MUELLER, KUSNE, RAMPRASAD; 2016).....	26
Figura 2.7 - Modelo de Decision Tree (MUELLER, KUSNE, RAMPRASAD; 2016).....	27
Figura 3.1 - Fluxograma geral da metodologia de pesquisa	38
Figura 3.2 - Relatório de Qualidade do cimento CPIV (Fornecido pela indústria cimenteira).....	39
Figura 4.1 - Correlação das Variáveis da BDG.....	52
Figura 4.2- Resultados do Treinamento do Algoritmo A1	60
Figura 4.3 - Resultados do Teste de algoritmo A1.....	61
Figura 4.4 - Resíduos de erro relativo nas previsões do algoritmo A1	64
Figura 4.5 - Resultados do Treinamento do Algoritmo A2	65
Figura 4.6 - Resultados do Teste do Algoritmo A2	66
Figura 4.7 - Resultados do Treinamento do Algoritmo B1.....	69
Figura 4.8 - Resultados de Teste do Algoritmo B1.....	71
Figura 4.9 - Resultados do Treinamento do Algoritmo B2.....	72
Figura 4.10 - Resultados do Teste do Algoritmo B2	74
Figura 4.11 - Resíduos de erro relativo nas previsões do algoritmo B2	75
Figura 4.12 - Resultados do Treinamento do Algoritmo B3.....	76
Figura 4.13 - Resultados do Teste do Algoritmo B3	77
Figura 4.14 - Resíduo do erro relativo de treinamento e teste do Modelo A1	82
Figura 4.15 - Resíduo do erro relativo do treinamento e teste do Modelo B2	82

1 INTRODUÇÃO

1.1 IMPORTÂNCIA DO TEMA

O concreto é um dos materiais mais consumidos no mundo atualmente. Entre os materiais constituintes do concreto atribui-se grande destaque para o cimento Portland (CP), uma vez que as propriedades dos concretos surgem como resultado das reações que envolvem esse aglomerante (MEHTA e MONTEIRO, 2014). Esse fato justifica a elevada demanda por cimento Portland pela indústria da construção civil o que tem impulsionado a sua produção. Em 2019 foi estimada uma produção mundial de 4,1 bilhões de toneladas de cimento para consumo (CEMBUREAU, 2020). Essa demanda por cimento Portland foi discutida no Roadmap Tecnológico de Cimento (2019), que apontou uma tendência de aumento da produção de cimento Portland no Brasil até o ano de 2045, com valores de produção nacional de mais de 160 Mt de cimento anuais, conforme apresentado na Figura 1.1.



Figura 1.1 - Projeção da Produção de Cimento no Brasil para cenários de alta e baixa demanda do material (VISED0 e PECCHIO, 2019)

O cimento Portland comum é constituído por uma mistura de clínquer e gipsita, sendo o primeiro seu principal constituinte (NEVILLE e BROOKS, 2013). Contudo, existem classes de cimento que apresentam outros materiais constituintes além dos mencionados. Esses materiais são conhecidos como Materiais Cimentícios Suplementares (MCS) e tem ganhado destaque nos últimos anos.

A indústria da construção civil tem sido motivada a produzir e utilizar cimentos Portland com maior teor de MCS e menor porcentagem de clínquer (ANTONI et al., 2012; VISEDO e PECHIO, 2019; e ASTERIS et al., 2021). Isso porque a produção do clínquer resulta em elevados gastos energéticos e liberação de CO₂ devido à etapa de calcinação do calcário que deve atingir elevadas temperaturas. Além disso, são gerados elevados gastos energéticos para o aquecimento e manutenção da temperatura no interior do forno rotativo que geralmente envolvem outra parcela elevada de liberação de CO₂. Segundo LHENE e PRESTON (2018) apenas a indústria cimenteira é responsável por 8% de toda emissão de CO₂ liberada na atmosfera. Já os MCS costumam apresentar valores menores de gasto energético por serem advindos de jazidas naturais ou subprodutos de rejeitos industriais, de acordo com SCRIVENER (2014) e MEHTA e MONTEIRO (2014).

Essa situação tem motivado cada vez mais a produção de cimentos com menor teor de clínquer, como o cimento Portland Pozolânico Tipo IV (CPIV). Essa classe de cimento é caracterizada pela presença em sua composição de teores de até 50% de MCS pozolânicos (ABNT, 2018). Esse elevado teor de MCS pozolânico reduz o consumo de clínquer do cimento, tornando o CPIV muito menos nocivo ao meio ambiente.

Contudo, é importante ressaltar que a incorporação de MCS ao cimento, como no caso do CPIV, conduz a alterações na cinética de hidratação da mistura cimentícia (SCRIVENER, 2019). Sabendo disso, é necessário que a composição dessa mistura seja controlada de forma a se fabricar um produto adequado para uso, tanto em termos de desempenho na construção civil, quanto em termos ambientais. Levando em consideração o primeiro, foram definidos diversos parâmetros normativos para se garantir a qualidade do cimento Portland, conforme observado na NBR 16697 (ABNT, 2018).

Um dos principais parâmetros controlados pela NBR 16697 (ABNT, 2018), que tem foco no comportamento do cimento em seu estado endurecido é a resistência à compressão aos 28 dias. Segundo a NBR 16697 (ABNT, 2018), existem também requisitos químicos definindo teores máximos de compostos em cada classe de cimento Portland, como os teores de Perda ao fogo, teor de trióxido de enxofre (SO₃) e resíduo insolúvel. Além destes requisitos químicos, existem também os mecânicos, como a expansibilidade à quente, o resíduo na peneira 75 µm e a já mencionada resistência à compressão em diferentes idades. Fica nítido que há uma quantidade considerável de parâmetros a serem controlados durante a fabricação do cimento e que estes podem influenciar em seu comportamento.

Durante uma avaliação de um cimento Portland é necessário que sejam avaliados os parâmetros citados anteriormente para se caracterizar corretamente o aglomerante. Os processos necessários para avaliar todas essas propriedades demandam quantidades de tempo e materiais consideráveis. Dessa forma o processo como um todo se torna oneroso (por conta da necessidade de se produzir diferentes amostras para diferentes ensaios) e moroso no caso de ensaios como resistência à compressão (que pode chegar a demandar programações para mais de 28 dias). Tendo isso em vista, se torna interessante o estudo de técnicas alternativas que possam tornar o processo de determinação dessas propriedades mais eficiente em termos de consumo de material e tempo demandado para avaliar as amostras.

Uma das formas mais recentes que vem sendo pesquisadas para se compreender o comportamento de bancos de dados de múltiplas variáveis, é o uso de técnicas de *Machine Learning* (ML). Segundo Bullard et al. (2019), o termo ML é utilizado para descrever algoritmos que exploram de forma sistemática um espaço amostral de forma a otimizar a caracterização deste e descobrir relações entre os seus componentes. A incorporação de ML já vem sendo implementada em diversas outras áreas de conhecimento com variados tipos de análises nos últimos anos, como campos de bioinformática, teoria dos jogos e previsão de eventos (MUELLER, KUSNE, RAMPRASAD, 2016; BEN CHAABENE, 2020; VAKHARIA e GUJAR, 2019). Isso se tornou possível devido aos diversos tipos de abordagens e estratégias que podem ser utilizadas por meio de *Machine Learning* (ML) e que mais recentemente vem também sendo aplicadas no campo de materiais de construção civil.

1.2 MOTIVAÇÃO DA PESQUISA

Esse trabalho segue as linhas de pesquisa “Tecnologia, Processos, Componentes e Materiais de Construção” e “Métodos Numéricos e Computacionais Aplicados à Engenharia” do Programa de Pós-graduação em Estruturas e Construção Civil (PECC) da Universidade de Brasília (UnB). Outras pesquisas utilizando *Machine Learning* já foram realizadas no PECC nos campos de Estruturas e de Gestão, como no grupo de pesquisa Numerical, Experimental and Uncertainty Mechanics Research Group (NEXUM), contudo essa pesquisa é uma das primeiras do PECC a utilizar técnicas de ML na área de Materiais de Construção Civil, sendo sequência do trabalho que vem sendo desenvolvido por Jéssica Fall Nogueira Soares, que utiliza técnicas de *Machine Learning* para prever o comportamento mecânico de cimentos Portland Tipo I (CPI), com orientação pelos professores João Henrique da Silva Rêgo e Francisco Evangelista Junior.

No caso deste trabalho será estudado o cimento CPIV que pode ser caracterizado pela presença de MCS pozolânico (argila calcinada), clínquer, gipsita e fíler calcário. Desse modo o comportamento do CPIV depende de um maior número de variáveis do que o cimento comum, o que implica em maior dificuldade em se prever suas propriedades em comparação ao CPI. Já é estabelecido na literatura que o comportamento de misturas contendo MCS pozolânicos, como as fabricadas com CPIV, difere do apresentado por misturas com CP comum (SCRIVENER, 2021; ANDRADE, 2017).

Há relativamente poucos trabalhos publicados na literatura que tratem da previsão de comportamento do cimento Portland por meio de técnicas de *Machine Learning*. Nota-se ainda por meio da revisão da literatura realizada que a maior parte destas pesquisas surgiu nos últimos 10 anos. Trabalhos como os de Asteris et al. (2021), Kumar e Naranje (2019), Ozcan et al. (2017), Kumar et al. (2021), Gayathri et al. (2022) e Turk et al. (2023) tratam do uso de *Machine Learning* para prever propriedades de cimentos. Há um foco considerável em específico na resistência à compressão do concreto na maioria dos trabalhos já publicados, uma vez que este é um dos principais parâmetros em termos de projeto de estruturas de concreto. Ademais, não foram encontrados trabalhos que foquem apenas em cimentos pozolânicos de uma única indústria de cimento e que investiguem a influência de diferentes tipos de bancos de dados no desempenho das previsões.

Desse modo esse trabalho pretende atuar no *gap* da pesquisa existente, que é a previsão das propriedades do cimento CPIV, produzido por uma única fábrica de cimento por meio de técnicas de ML com diferentes tipos de bancos de dados (montados com os parâmetros de fabricação do CP dessa mesma fábrica).

1.3 OBJETIVOS

1.3.1 OBJETIVO GERAL

O objetivo principal da pesquisa é prever a resistência à compressão do cimento Portland Pozolânico - tipo IV (CPIV), com argila calcinada, fabricado por uma indústria cimenteira localizada no DF, a partir de diferentes bancos de dados, por meio de técnicas de *Machine Learning*.

1.3.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos da pesquisa são:

- Elaborar bancos de dados com propriedades do cimento Portland tipo IV, produzido pela cimenteira analisada, de forma que esses possam ser utilizados para estudo da previsão de propriedades do CPIV;
- Fazer a previsão de valores de resistência à compressão do cimento CPIV aos 28 dias por meio do uso de teores de óxidos do cimento;
- Fazer a previsão de valores de resistência à compressão do cimento CPIV aos 28 dias por meio do uso de compostos principais do cimento;
- Avaliar a influência de diferentes parâmetros como *inputs* dos bancos de dados analisados no desempenho das previsões realizadas; e
- Comparar os algoritmos elaborados e analisar qual apresenta melhor desempenho geral na predição da resistência à compressão do CPIV.

1.4 ESTRUTURA DO TRABALHO

Este trabalho é dividido em 5 capítulos, uma seção de referências bibliográficas e dois apêndices. O primeiro capítulo trata da introdução ao tema, com a importância do tema, motivação da pesquisa e objetivos almejados. No segundo capítulo é apresentada uma revisão da literatura relativa ao tema da pesquisa. Este capítulo se aprofunda na composição do cimento Portland e suas propriedades e no uso de técnicas de *Machine Learning* na área de materiais de construção civil. Já o terceiro capítulo consiste na metodologia da pesquisa, detalhando os procedimentos, dados e técnicas adotados na elaboração do trabalho. No quarto capítulo são apresentados e discutidos os resultados obtidos através dos procedimentos definidos no capítulo anterior. Por fim o quinto capítulo apresenta as conclusões obtidas a partir desse trabalho. Em seguida são apresentadas as referências bibliográficas adotadas, e ao final no Apêndice é apresentada a Base de Dados elaborada nesse trabalho.

2 REVISÃO DA LITERATURA

Neste capítulo serão apresentadas as bases teóricas relativas ao trabalho. Será inicialmente tratado sobre a composição geral do cimento Portland e suas categorias normalizadas no Brasil. Em seguida serão abordados mais a fundo as propriedades e o comportamento dos cimentos Pozolânicos. Além disso, serão apresentadas as bases teóricas do funcionamento do *Machine Learning*, as pesquisas mais atuais em relação ao uso de ML em materiais cimentícios e suas aplicações específicas ao uso com cimentos Portland.

2.1 CIMENTO PORTLAND

O cimento Portland é um dos principais materiais construtivos utilizados na atualidade. Isso devido ao fato de ser um material em pó, com fácil transporte e um aglomerante hidráulico, ou seja, capaz de resistir à água depois de hidratado (MEHTA E MONTEIRO, 2014). Além disso, a mistura do cimento Portland (CP) com água e agregados (grãos e miúdos) em diferentes proporções é capaz de gerar misturas cimentícias como concretos e argamassas que podem ser utilizados com diferentes finalidades em diversos tipos de elementos construtivos.

A *International Energy Agency* (IEA) estima que foram produzidas 4,1 Gt de cimento no ano de 2019 em todo o mundo. Já segundo o Sindicato Nacional da Indústria do Cimento (SNIC,2021), apenas em julho de 2021 foram vendidas 5,94 milhões de toneladas de cimento no Brasil. Ainda segundo a SNIC, isso é fruto do aquecimento do mercado brasileiro de construção civil no último ano que vem motivando uma elevação do consumo do CP no território nacional. Esse fato comprova como o cimento é essencial para sistema construtivo tradicional brasileiro, e corrobora com os estudos de Souza (2021) que indicam que o crescimento da produção de cimento é fruto de um crescimento na indústria da construção civil no Brasil.

Segundo a IEA (2020) e o Roadmap Tecnológico do Cimento (2019) há uma tendência de aumento considerável na produção de CP até o ano de 2030. Esse crescimento é fruto das propriedades do CP, que permitem sua ampla aplicação nos mais diversos campos da construção civil. Estas propriedades são oriundas da composição química desse aglomerante, que influencia diretamente seu processo de hidratação, o que justifica o controle rigoroso da produção do cimento Portland. A fim de se compreender mais a fundo as propriedades do CP

e como estas se desenvolvem, é preciso analisar a sua composição química, e como esta influência o comportamento de misturas cimentícias.

2.1.1 Composição Química do Cimento Portland

Grande parte das propriedades do cimento Portland (e por consequência, de misturas contendo-o) podem ser explicadas por sua composição química. Devido a essas propriedades, ao entrar em contato com a água o cimento anidro reage apresentando rápido ganho de resistência em suas primeiras idades e mantém uma taxa de reação contínua após isso (KUMAR e NARANJE, 2019). Esse processo é justificado primeiramente pelo fato de o cimento Portland (CP) ser um aglomerante hidráulico, o que como já explicitado, o faz manter sua resistência ao ser exposto à água. Contudo, para compreender mais a fundo o comportamento do CP é preciso analisar a composição de seu principal componente: o clínquer.

O clínquer anidro é produzido a partir do calcário, argilas e materiais silicosos, por meio de processos de britagem, moagem, mistura e tratamento térmico destes materiais, até que estes originem o clínquer (MEHTA e MONTEIRO, 2014). Esse material é rico em cálcio e sílica, sendo constituído por quatro compostos principais sendo eles: a alita, ou silicato tricálcico (C_3S); a belita, ou silicato (C_2S); o aluminato tricálcico (C_3A); e ferroaluminato tetracálcico (C_4AF) (NEVILLE e BROOKS, 2013). Estes componentes são os principais responsáveis pelo comportamento do clínquer, e por consequência do CP. A hidratação da alita e da belita é a reação responsável pela produção do C-S-H, que é o composto que garante o desempenho mecânico da pasta de cimento, enquanto as reações de hidratação do C_4AF e do C_3A garantem a produção dos produtos aluminatos (MEHTA e MONTEIRO, 2014; NEVILLE e BROOKS, 2013). Ademais, é válido ressaltar que o processo de hidratação da alita e da belita é o principal responsável pela formação do Hidróxido de Cálcio, composto que não contribui tanto quanto o C-S-H para o desempenho mecânico, mas que é reagente essencial para a ocorrência de reações pozolânicas (TURK et al., 2023).

Além do clínquer, um segundo composto essencial na constituição do CP é a gipsita. Esta é responsável por reagir com o C_3A , impedindo a formação imediata de Etringita e por consequência o processo de pega instantânea, com a formação de placas hexagonais de hidratos que não fornecem resistência mecânica e diminuem a trabalhabilidade da mistura.

Segundo Mehta e Monteiro (2014), Huang et al. (2022) e Turk et al. (2023) o teor presente de cada composto do CP influencia no desempenho da mistura cimentícia. Dessa forma o processo de fabricação do CP visa controlar os parâmetros de produção de maneira a manter os teores de cada composto do cimento em valores específicos a fim de se obter um material com comportamentos dentro de intervalos predefinidos por norma.

Segundo a norma brasileira, o cimento mais simples (em termo de composição química) que se pode produzir é o que contém apenas clínquer e gipsita, conhecido como Cimento Portland Comum - Tipo I (CPI). Segundo a NBR 16697 (ABNT, 2018) este pode ser composto por até 4,5% de SO_3 (que advém da gipsita) e sendo o restante de sua composição (aproximadamente 95%) relativa apenas ao clínquer. Contudo, a norma mencionada permite a incorporação de até 5% de MCS, ou seja: Fíler Calcário; Escória; ou Pozolanas, sendo o mais comum a incorporação do Fíler.

Desse modo pode-se perceber que o CPI é caracterizado por elevado teor de clínquer. Contudo, o processo de fabricação do clínquer é o grande responsável pela elevada liberação de CO_2 na fabricação do cimento. Isso se dá principalmente pela etapa de calcinação da matéria prima do clínquer, processo que consiste no aquecimento desse material em forno rotativo a temperaturas de aproximadamente $1450\text{ }^\circ\text{C}$ para garantir a ocorrência das reações químicas que formarão o clínquer (MEHTA e MONTEIRO, 2014). Esse processo inclui a descarbonatação do carbonato de cálcio ($CaCO_3$) resultando em elevados teores de liberação de CO_2 que correspondem a até 50% das emissões liberadas no processo de fabricação do cimento (BATTAGIN, 2016).

Assim, existe uma tendência cada vez maior do uso de cimentos compostos, ou seja, com substituição de diferentes teores de clínquer por materiais cimentícios suplementares (MCS). Essa ação torna a produção do cimento menos agressiva ambientalmente ao utilizar MCS que advém de resíduos industriais ou de fontes naturais e que muitas vezes exigem tratamento prévio menos dispendioso energeticamente.

A incorporação de MCS ao cimento Portland altera o comportamento de uma mistura cimentícia, gerando compósitos com propriedades e aplicações diferenciadas. Isso devido aos diversos efeitos físicos e químicos que os MCS apresentam ao serem acrescentados nas misturas cimentícias (DE LA VARGA et al., 2018).

Dessa forma a NBR 16697 (ABNT, 2018) existe com o fim de regularizar a composição dos diferentes tipos de cimento (compostos ou não) produzidos e vendidos no Brasil. Tal norma foi criada no ano de 2018 de forma a readequar a composição das classes de CP no país com a nova realidade de materiais e tecnologias envolvendo a produção e composição do clínquer, dos diferentes MCS e vários tipos de cimentos Portland comercializados no Brasil.

2.1.1.1 Técnicas de Avaliação da Composição Química do Cimento Portland

As principais técnicas utilizadas para se determinar a composição química do cimento Portland são os ensaios de Espectrometria por Fluorescência de Raio – X (FRX) e Difração por Raio-X (DRX). Contudo, embora ambas as técnicas forneçam resultados relativos à composição do cimento, estas não devem ser confundidas, uma vez que fornecem aspectos completamente diferentes da composição do material analisado. Porém é importante destacar que o DRX e o FRX são ensaios complementares que unidos conseguem apresentar um retrato da composição do cimento Portland analisado de melhor forma do que separados.

Os ensaios de FRX consistem na análise química de uma amostra e detecção quantitativa do teor de óxidos no material analisado (ASFORA, 2010). Dessa forma, os resultados desse ensaio informarão apenas as porcentagens em massa de cada tipo de óxido detectado na amostra. No caso de análises de cimento Portland é comum encontrar teores em concentrações mais relevantes de óxidos como SiO_2 , CaO , MgO , K_2O e Al_2O_3 . Contudo, não é possível identificar quais compostos exatamente se encontram na composição do material analisado ou se estes se apresentam em forma cristalina ou amorfa. Entretanto, devido ao fato de fornecer resultados quantitativos, o FRX é frequentemente utilizado para controle e análise de produção do cimento Portland (o que não descarta o uso dos ensaios de DRX pelas cimenteiras).

Já os ensaios de DRX analisam amostras de materiais a partir dos padrões de refração de ondas que são lançadas sobre o material analisado. A partir desses padrões é possível determinar que tipo de composto químico que compõe a amostra e ainda é possível avaliar qualitativamente se há maior ou menor concentração dos compostos de acordo com a intensidade de cada padrão de refração. Segundo Palacios et al. (2016) cada tipo de estrutura cristalina gera um padrão de refração diferente que é utilizado nesse ensaio para caracterizar a composição da amostra analisada. Isto significa que o DRX é capaz de informar se em certa amostra de cimento Portland anidro há teores de C_3S , impurezas, C_2S entre outros compostos.

É válido ressaltar que devido à natureza do ensaio (análise de padrões de refração de ondas) esse tipo de ensaio é focado em detectar compostos cristalinos, o que é o caso para a grande maioria dos compostos no cimento anidro.

Outra alternativa já conhecida e difundida para a quantificação dos compostos principais do cimento Portland (por meio dos teores de óxidos obtidos pelo ensaio de FRX) é o uso das Fórmulas de Bogue. Tal estratégia é ideal apenas para cimentos puros, sem incorporação de MCS ou outros compostos como o gesso. Na presença desses materiais devem ser realizadas adequações na composição e/ou equações a fim de se obter teores de compostos principais de forma correta (GOBBO, 2009). Ainda segundo Chaves (2021) e Gobbo (2009) as fórmulas de Bogue contam com limitações e aproximações que podem tornar os seus resultados menos confiáveis. As fórmulas são apresentadas nas Equações 2.1 a 2.4.

$$C_3S = (4,07 \times (\text{CaO} - \text{CaO}_{\text{livre}})) - (7,6 \times \text{SiO}_2) - (6,72 \times \text{Al}_2\text{O}_3) - (1,43 \times \text{Fe}_2\text{O}_3) - (2,85 \times \text{SO}_3) \quad (2.1)$$

$$C_2S = (2,87 \times \text{SiO}_2) - (0,754 \times C_3S) \quad (2.2)$$

$$C_3A = (2,65 \times \text{Al}_2\text{O}_3) - (1,69 \times \text{Fe}_2\text{O}_3) \quad (2.3)$$

$$C_4AF = 3,04 \times \text{Fe}_2\text{O}_3 \quad (2.4)$$

Contudo, há uma categoria mais recente de ensaio, menos utilizada que as demais que é capaz de fornecer uma análise mais completa da composição química do cimento, o DRX-*Rietveld*. Essa técnica especial de DRX atua similarmente ao DRX padrão, contudo é capaz de também quantificar numericamente a concentração dos compostos detectados, fornecendo um retrato da composição do cimento muito mais completo que o DRX ou o FRX (GOBBO, 2009; PALACIOS et al., 2016; CHAVES, 2021). Esse tipo de técnica, no entanto demanda considerável experiência técnica para ser realizada e quantidade de tempo para se obter os teores de cada composto detectado (PALACIOS et al., 2016). Entretanto, esse tipo de ensaio ainda possui acesso mais restrito no Brasil e demanda elevados custos devido à baixa oferta no meio acadêmico e profissional.

2.1.2 Categorias de Cimento Portland – NBR 16697 (ABNT, 2018)

A NBR 16697 (ABNT, 2018) é a norma brasileira vigente que especifica os requisitos para a produção de cada tipo de cimento. A Tabela 2.1 apresenta a composição normativa de cada tipo de CP regularizado no Brasil segundo a última revisão da norma citada (realizada

em 2018). Nota-se que há três grandes categorias de MCS apresentadas pela norma: as Escórias de Alto Forno (E), os Fíleres (F) e as Pozolanas (Z).

Tabela 2.1 Composição das Classes de CP segundo a NBR 16697 (ABNT, 2018)

Cimento Portland (ABNT)	Tipo de Cimento	Componentes (%)			
		Clínquer + Sulfato de Cálcio	Escória de Alto-Forno (E)	Material Pozolânico (Z)	Material Carbonático (F)
CPI	Cimento Comum	95-100	0 a 5	0 a 5	0 a 5
CPI-S	Cimento Comum	90-94	0	0	6 a 10
CPII-F	Cimento Composto	75-89	0	0	11 a 25
CPII-E	Cimento Composto	51-94	6 a 34	0	0 a 15
CPII-Z	Cimento Composto	71-94	0	6 a 14	0 a 15
CPIII	Alto-Forno	25-65	35 a 75	0	0 a 10
CPIV	Pozolânico	45-85	0	15 a 50	0 a 10
CPV	Alta Resistência Inicial	10-100	0	0	0 a 10

Ao analisar a Tabela 2.1 é possível notar que os cimentos CPI, CPI-S são os que apresentam maior teor de clínquer em sua composição. Isso se deve ao fato de que estes são classificados como CP comuns, com teores de substituição relativamente baixos, e em função do já mencionado impacto ambiental e elevado custo para se produzir este material estas classes são as que se encontram em menor disponibilidade comercialmente. Nota-se ainda que entre as demais classes, o CPV é o que apresenta teores mais próximos do CPI, isso se deve à sua composição e por ser um cimento de alta resistência inicial. A NBR 16697 (ABNT, 2018) exige valores de resistência à compressão mais elevados do que as demais classes já aos 7 dias de idade, o que é mais facilmente atingido com o uso de teores mais altos de clínquer combinados com mais elevada finura do cimento.

Já os cimentos do tipo II (CPII) são classificados como compostos por possuírem teores consideráveis de MCS em sua composição. Nota-se que entre os 3 tipos de CPII existe a possibilidade de até 49% de substituição de clínquer por MCS (no caso do CPII-E, que pode conter fíler e escória de alto forno, material consideravelmente pozolânico). Há ainda os cimentos CPIII e CPIV, que apresentam os maiores teores de substituição entre todas as classes, por serem classificados como cimentos de alto forno e pozolânico, respectivamente. No caso do CPIII, o MCS utilizado é um subproduto industrial (a Escória de Alto-Forno) gerando diminuição de impacto ambiental, enquanto no CPIV são utilizadas pozolanas (que podem variar de origem conforme a região de fabricação) e que em grande parte dos casos vem de jazidas naturais ou de subprodutos (ou até resíduos) industriais assim como a escória.

Nota-se ainda que para o cimento CPIV são liberados teores de substituição elevados, chegando a uma substituição máxima de 50% do clínquer por pozolanas. Esse teor elevado de substituição só se torna possível devido às reações pozolânicas que ocorrem devido à incorporação dos materiais pozolânicos, garantindo ganhos consideráveis de resistência a partir dos 7 dias de idade (ANTONI, 2012; VASQUES, 2019; ASTERIS et al., 2021; HUANG et al., 2022; TURK et al., 2023). É importante ressaltar que o CPIV ainda pode conter até 10% de fíler em sua composição (material que atua apenas por efeitos físicos no desempenho mecânico da mistura). No caso mais extremo de incorporação de MCS, pode-se atingir um teor de substituição de 55% do clínquer por pozolanas e fíler combinados.

A NBR 16697 (2018) ainda regula parâmetros como teores de MgO, SO₃, Perda ao Fogo, expansibilidade a quente, tempos de pega (inicial e final) e granulometria para cada categoria de cimento Portland. Neste trabalho a classe de cimento a ser avaliada é o CPIV, como já mencionado anteriormente, dessa forma, serão detalhadas a seguir as especificações deste tipo de CP, conforme apresentado na Tabela 2.2.

Tabela 2.2 - Limites Normativos segundo a NBR 16697/2018 para o CPIV (fonte: autor)

Propriedade	Limite Normativo
Resíduo na Peneira 75 micrômetros (%)	≤ 8,0
SO ₃ em massa (%)	≤ 4,5
Tempo de Início de Pega (min)	≥ 60
Tempo de Fim de Pega (min)	≤ 720
Resíduo Insolúvel (%)	-
Perda ao Fogo (%)	≤ 6,5
Expansibilidade à Quente (mm)	≤ 5,0
MgO em massa (%)	-
Anidrido Carbônico (%)	≤ 5,5

O Resíduo na Peneira 75 µm é um indicativo da finura do CP analisado. Este representa a porcentagem em massa de uma amostra de cimento que ficou retida na malha de 75 µm após o peneiramento desta. Quanto menor o valor desse parâmetro mais fino o CP tende a ser. Um material mais fino apresentará maior superfície específica e por consequência maior reatividade inicial com a água.

O teor de SO₃ pode ser associado ao teor máximo de gipsita adicionado ao cimento durante sua fabricação. Como comentado anteriormente é este composto que atua impedindo a pega instantânea do cimento, garantindo que o C₃A não reaja antes do C₃S afetando a formação dos compostos principais do cimento.

Os tempos de início e fim de pega são relacionados à trabalhabilidade do cimento em seu estado fresco e indicativos da perda de plasticidade da mistura. Segundo a NBR 16607 (ABNT, 2018) o Tempo de Pega Inicial é o tempo entre a adição de água de amassamento e a penetração da agulha de Vicat entre 3 e 5 mm da base de um corpo de prova, correlacionando esse parâmetro com o período em que a mistura cimentícia fresca se encontra trabalhável. Já o Tempo de Pega Final é caracterizado pela NBR 16607 (ABNT, 2018) como o tempo desde a adição de água de amassamento até que a penetração da agulha de Vicat penetre apenas 0,5 mm na pasta de cimento, desse modo este parâmetro pode ser correlacionado com o tempo necessário para o início do endurecimento da mistura cimentícia.

Já o Resíduo Insolúvel é a porcentagem em massa de material que não se solubiliza após um ataque de cloro à amostra. O limite para este parâmetro nas classes de cimento que não contêm pozolanas (CPI, CPII-E, CPII-F, CPIII e CPV) atinge o valor máximo de 7,5% segundo a NBR 16697 (NBR, 2018). Contudo, não há limite desse parâmetro para o CPIV uma vez que este tende a apresentar valores mais elevados (em torno de 25% no caso do cimento analisado neste trabalho), uma vez que é composto por teores consideráveis de material pozolânico.

A expansibilidade à quente é um ensaio que se correlaciona com a expansão volumétrica tardia de compostos na mistura cimentícia. Valores acima do limite normativo podem resultar em CP que apresentarão expansão de seus produtos de hidratação resultando em comprometimento de seu desempenho. Já o Anidrido Carbônico (CO_2) está relacionado com a porcentagem de materiais que após aquecimento podem passar por processo de descarbonatação liberando esse composto.

A Perda ao Fogo representa a porcentagem de massa perdida em uma amostra após calcinação e decomposição à temperatura de 950 °C. Quanto maior esse valor maior o teor de compostos contendo água adsorvida ou em sua composição. Este parâmetro também pode ser relacionado com a carbonatação precoce e hidratação do MgO e CaO presentes na composição do cimento após exposição ao ar. Devido a isso, outro parâmetro controlado é o teor de óxido de Magnésio (MgO) presente na composição do cimento. Este parâmetro é um indicativo da presença de impurezas no CP e em teores elevados pode resultar em reações expansivas na pasta de cimento (MEHTA E MONTEIRO, 2014).

A versão vigente da NBR 16697 realizada em 2018 redefiniu os parâmetros apresentados na Tabela 2.1 e na Tabela 2.2. Em comparação à sua versão anterior houve um aumento nos limites de fíler permitido em diversas categorias de CP, reduzindo a quantidade de clínquer mínima necessária em várias das classes de cimento Portland. Esse fato é um dos indicadores da tendência de aumento de uso de MCS e de uma preocupação da indústria com o aumento de custos e danos ao meio ambiente.

Essa atenção de toda a cadeia produtiva do cimento que vem sendo dada para a redução no consumo de clínquer no Brasil vem motivando o uso de MCS (VISEDIO e PECCHIO, 2019), assim como tem ocorrido no resto do mundo (BANSAL et al., 2022). Tendo isso em vista, o uso de cimentos compostos, como o CPIV, CPIII e o CPII se torna mais atraente do ponto de vista econômico para a indústria. Contudo, é importante ressaltar que a incorporação dos diferentes MCS contidos nesses cimentos resulta em alterações na composição química, e por consequência no comportamento e desempenho das misturas cimentícias.

A fim de se compreender o comportamento do cimento utilizado nesta pesquisa, o CPIV, é necessário que se aprofunde nas consequências da incorporação de pozolanas no CP, com o estudo dos cimentos pozolânicos.

2.2 COMPORTAMENTO DE CIMENTOS POZOLÂNICOS (CPIV)

Cimentos pozolânicos são aqueles caracterizados pela incorporação de pozolanas em sua composição. Devido a isso, o comportamento desse cimento composto é fortemente influenciado pela presença dessas pozolanas, contudo é válido ressaltar que certo teor de fíler também pode ser incorporado neste cimento (conforme apresentado na Tabela 2.1). De acordo com a NBR 12653 (ABNT, 2014), pozolanas são MCS silicosos (ou sílico-aluminosos) que possuem pouca ou nenhuma propriedade aglomerante por si só, porém ao estar finamente dividida e na presença de água, reage quimicamente e forma compostos com propriedades aglomerantes.

Desse modo, fica claro que as pozolanas agem principalmente por meio de seu efeito químico, as reações pozolânicas. Estas consistem na interação entre o MCS pozolânico e a portlandita (CH), originária das reações de hidratação do clínquer, formando novas fases de C-S-H na mistura cimentícia (MURAT, 1983; ARAMBURO et al., 2019; TURK et al., 2023).

Há uma tendência de se utilizar cada vez mais MCS em substituição ao clínquer na produção do cimento Portland (SCRIVENER, 2014; ASTERIS et al., 2021). Esse fato vem proporcionando maior destaque para classes de cimento que permitem maiores teores de materiais suplementares, principalmente os pozolânicos, como o CPIV e o cimento LC3 (ANTONI et al., 2012).

Há diversos tipos de materiais que são classificados como pozolânicos e utilizados como MCS em misturas cimentícias. Entre estes pode-se citar a cinza volante (DE LA VARGA et al., 2018; HONG et al., 2016; BERNAL et al., 2016) e as argilas calcinadas (LINS, 2017; MARAGHECHI et al., 2018; VASQUES, 2019; ARAMBURO et al., 2019; ASTERIS et al., 2021; TURK et al., 2023). Contudo, cada tipo de MCS apresenta efeitos específicos na cinética de hidratação de misturas cimentícias (SCRIVENER et al., 2019). Desse modo este trabalho se aterá aos efeitos do tipo de pozolana adotado no CPIV estudado, a saber, argilas calcinadas (AC).

Segundo Pinheiro (2018) a AC é a principal pozolana utilizada como matéria-prima no Distrito Federal (DF) para produção de cimentos Portland. De acordo com o Roadmap Tecnológico do Cimento (2019) esse material é também um dos principais MCS a ser adotado nas próximas décadas para produção de cimentos Portland com menores teores de clínquer. Dessa forma é conveniente que sejam produzidas e analisadas novas técnicas para se estudar e prever as propriedades dos cimentos pozolânicos que utilizem argilas calcinadas.

As argilas calcinadas (AC) são produzidas a partir de argilas naturais. Estas não apresentam reatividade considerável com cal a menos que passem por tratamento específico. Segundo Mehta e Monteiro (2014), as estruturas cristalinas dos minerais argilosos das argilas naturais são modificadas por um tratamento térmico que gerará como produto a argila calcinada. Esse tratamento térmico, conhecido como calcinação, dependerá da origem da argila e de sua estrutura molecular (GARCIA et al., 2015; YANGUATIN et al., 2017; ASTERIS et al., 2021, GAYATHRI et al., 2022).

O uso de argilas calcinadas como MCS é recomendado por Tironi et al. (2014). De acordo com os autores, as argilas calcinadas geram a redução da emissão de gases relacionados ao efeito estufa e diminuem a energia gasta na produção do cimento, além de possibilitar o aprimoramento de propriedades mecânicas e de durabilidade da mistura.

Ainda é mencionado por Tironi et al. (2014) que entre as categorias de argilas calcinadas, as caulínicas são as que apresentam maior reatividade pozolânica após o tratamento de calcinação e moagem. Ressalta-se que a AC utilizada no CPIV analisado neste trabalho tem sua origem em uma jazida de material majoritariamente caulínica.

Os estudos de Antoni et al. (2012) afirmam que as argilas calcinadas costumam surtir efeito de aumento da resistência à compressão mais pronunciado após os 7 dias de cura do material. Isso devido ao fato de que as reações pozolânicas se dão de forma lenta, e nas primeiras idades estes materiais atuam majoritariamente por meio do efeito de preenchimento. Além disso, a incorporação de argilas calcinadas ao CP leva ao aprimoramento do desempenho mecânico e da durabilidade das misturas cimentícias (ASTERIS et al., 2021).

Sabe-se que o CPIV estudado é um cimento composto com considerável teor de pozolana incorporado. Dessa forma este cimento costuma apresentar desenvolvimento mais acelerado de sua resistência à compressão a partir dos 7 dias de idade (ANTONI et al., 2012) e menor calor de hidratação, efeito das reações químicas geradas pelos materiais pozolânicos incorporados (GAYATHRI et al., 2022; AL-HASANI et al., 2023).

Segundo De La Varga et al. (2019), Asteris et al. (2021) e Al-Hasani et al. (2023), a incorporação de MCS pozolânicos gera efeitos físicos e químicos na mistura. Os efeitos químicos são consequência das reações pozolânicas, com o consumo da Portlandita e formação de C-S-H (e outros compostos aluminosos).

Já o efeito físico pode ser dividido em 3 partes que trabalham conjuntamente. A primeira sendo o efeito fíler, que consiste no preenchimento de vazios entre os grãos de cimento, com conseqüente refinamento de poros e compactação da estrutura (DE LA VARGA et al, 2018). Há também o efeito de nucleação, quando a superfície do MCS se torna ponto de nucleação para as reações de hidratação do cimento, o que traz como consequência a aceleração da reação do material. E por fim o efeito de espaçamento (ou diluição), que faz referência a um aumento virtual na relação água/cimento (a/c) devido ao aumento da distância entre os grãos de cimento devido à presença de MCS. Todos esses efeitos podem influenciar nas propriedades mecânicas (no estado endurecido) e na trabalhabilidade (estado fresco) da mistura cimentícia (TIRONI et al., 2014).

É importante ressaltar que a substituição de clínquer por pozolanas resultará em menor quantidade de C-S-H advinda da hidratação do clínquer. Dessa forma, é necessário que se leve esse fato em consideração nas primeiras idades, enquanto o efeito pozolânico não se desenvolve de maneira acentuada o que pode afetar o desempenho mecânico da mistura cimentícia nesse período. Esse fato precisa ser levado em conta durante a dosagem das misturas, a fim de se balancear tanto efeitos negativos quanto positivos.

Amer e El-Hoseny (2017) avaliaram a resistência à compressão de cimentos com incorporação de AC em teores de até 20% de substituição. Segundo os autores, aos 28 dias todas as misturas contendo cimentos com pozolanas apresentaram resultados equivalentes ou superiores ao da mistura de referência (sem incorporação de MCS). Foi encontrado como teor ótimo de substituição na pesquisa o valor de 5% de substituição de AC, contudo vale ressaltar que para cada tipo de AC será encontrado um teor ideal que dependerá de fatores como a/c, origem do MCS, composição química e mineralógica da argila.

Tironi et al. (2017) estudou o comportamento de cimentos pozolânicos com presença de argilas calcinadas e fíler. Os autores produziram traços contendo cimento comum (sem incorporação de MCS pozolânicos), cimentos pozolânicos (contendo 30% de argilas calcinadas) e misturas ternárias (contendo diferentes teores de fíler e AC). Os resultados de Tironi et al. (2017) indicam um maior desenvolvimento de resistência aos 28 dias para o traço contendo AC em relação ao traço contendo apenas cimento comum.. Foram estudados os traços PC (cimento comum), 10LF (cimento com 10% de substituição por fíler), 30CC (cimento pozolânico, com 30% de Argila Calcinada), 5LF15CC (cimento composto, com 5% de fíler e 15% de AC) e 10LF30CC (cimento composto com 10% de fíler e 30% de AC).

O traço 30CC apresenta resistência aproximada de 48 MPa aos 28 dias, enquanto o traço CP (cimento comum) apresenta 39 MPa. Esse comportamento é atribuído ao efeito pozolânico acentuado do MCS incorporado. Porém é ressaltado por Tironi et al. (2017) que esse efeito só ganha mais destaque a partir dos 7 dias e que o período anterior a este é mais fortemente influenciado pelos efeitos de diluição e fíler do MCS.

Ainda de acordo com os autores, a incorporação do fíler no cimento pozolânico é capaz de acelerar o processo de reações pozolânicas nas primeiras idades, o que intensifica o processo de ganho de resistência nessas idades. Observação que foi corroborada pelos ensaios

de Rietveld e análise do conteúdo de portlandita realizados pelos autores e pelos estudos de Aramburo et al. (2019).

Os estudos de Lins (2017), realizados na Universidade de Brasília, em argamassas contendo argila calcinada incorporada à um cimento CPI, de forma que esta mistura originou um cimento pozolânico. O trabalho utilizou uma adição de argila calcinada fornecida por uma cimenteira do Distrito Federal, a fim de comprovar seus efeitos na resistência à compressão de argamassas. Foram adotados teores de 15, 30, 45 e 60% de substituição de clínquer por AC (traços denominados A15, A30, A45 e A60 respectivamente) caracterizando cimentos pozolânicos, além do traço REF que é o único sem incorporação de AC, utilizando apenas um CPI. Os resultados de resistência à compressão de Lins (2017) para as idades de 1, 3, 7 e 28 dias são apresentados na Figura 2.1.

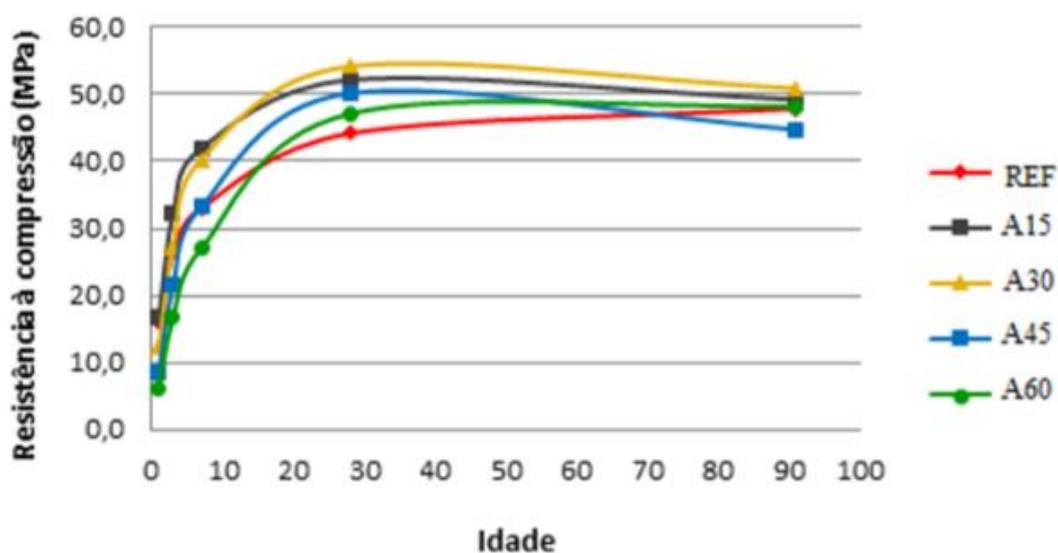


Figura 2.1 - Evolução da resistência à compressão das argamassas A15, A30, A45 e A60 (LINS, 2017)

Nota-se que na Figura 2.1 que todos os traços contendo AC apresentam resistência à compressão superior ao REF aos 28 dias de idade. Isso se dá pelos já mencionados efeitos pozolânicos característicos das AC incorporadas. É possível que apesar disso, nas idades iniciais o traço referência apresenta maiores valores de resistência, o que é explicado pelo efeito conjunto de seu maior teor de clínquer e pela velocidade lenta de reação característica das pozolanas.

Já Vasques (2019) trabalhou com a incorporação de teores de 15%, 25% e 35% de incorporação de dois tipos de AC a um CPI, produzindo cimentos pozolânicos diferindo apenas no tipo de AC e no seu teor incorporado. O autor avaliou o efeito dessa incorporação

na resistência à compressão do cimento produzido por meio do Índice de Desempenho das misturas. A Figura 2.2 apresenta os índices de desempenho para dois dos cimentos pozolânicos produzidos (A25 e B25), para um traço contendo apenas fíler (F25) e para o traço referência (REF) nas idades de 1, 3, 7 e 28 dias. Vale ressaltar que os três traços com MCS apresentados na figura contém teor de 25% de incorporação de seus respectivos MCS.

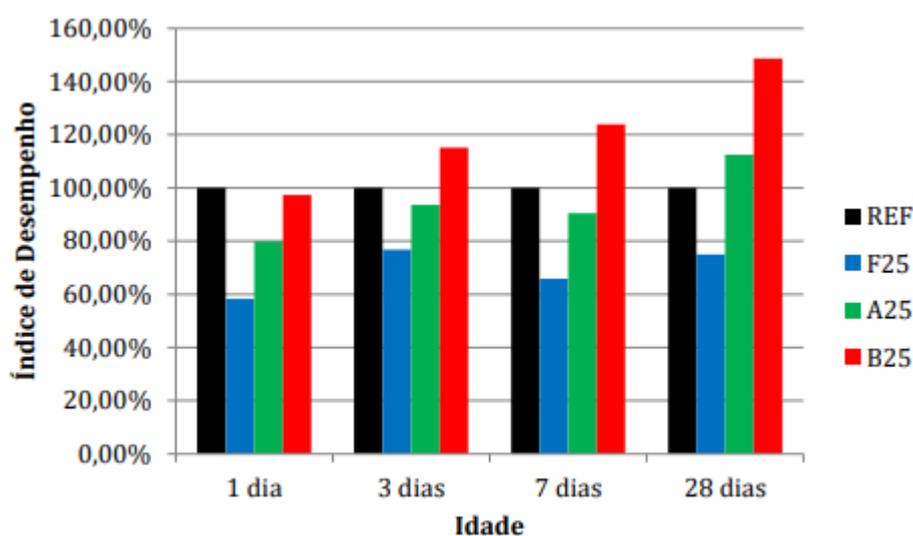


Figura 2.2 - Índice de Desempenho das misturas contendo 25% de substituição

Assim como nos estudos anteriores é possível perceber que aos 28 dias os traços de cimentos pozolânicos (A25 e B25) apresentaram desempenho superior ao traço contendo cimento comum. No caso do traço B25 os resultados já se tornam superiores aos 3 dias de idade, resultado da superfície específica elevada e reatividade pozolânica da AC utilizada (VASQUES, 2019). Neste estudo o desempenho do cimento comum se mostra superior ao de A25 apenas até os 7 dias de idade, no entanto quando comparado com o traço B25, o traço REF é praticamente equivalente já no 1º dia de idade da mistura. Esse comportamento evidencia a viabilidade do uso das AC do estudo como MCS para elaboração de cimentos pozolânicos, além de comprovar que esta classe de cimento pode apresentar desempenho equivalente ou superior ao do cimento comum no quesito de resistência à compressão.

A tendência de cimentos pozolânicos apresentarem valores de resistência à compressão inferiores em suas primeiras idades foi avaliada por Tironi et al. (2017). Segundo esse estudo, até os dois dias de idade a hidratação de uma mistura cimentícia pozolânica é fortemente governada pelo efeito de diluição advindo da incorporação do MCS e consequente espaçamento entre os grãos de cimento, que leva à uma menor atividade de hidratação do

cimento. Com o passar do tempo, os efeitos pozolânicos e de nucleação passam a influenciar mais intensamente as reações, produzindo o aumento de resistência característico a partir dos 7 dias de idade, conforme visto nos estudos de Vasques (2019), Lins (2017), Bediako et al. (2017), Turk et al. (2023) e diversos outros autores.

Vasques (2019) ainda avaliou o efeito da incorporação de AC no estado fresco dos cimentos produzidos. Todos os traços do estudo foram produzidos com teor a/aglomerante de 0,48 e o espalhamento na Mesa de Consistência foi fixado para que todos os traços apresentem trabalhabilidade similar. Contudo, foi notado que os traços contendo cimentos pozolânicos exigiram a incorporação de aditivo superplastificante em sua composição para que a mistura atingisse o espalhamento estipulado. Esse comportamento é explicado por Vasques (2019) como resultado da superfície específica mais elevada das pozolanas em relação ao CPI, fazendo com que a mistura no total demande mais água. Um aumento no teor de substituição de clínquer por AC resultou em consequente aumento na demanda por aditivo superplastificante, corroborando essa análise.

Aramburo et al. (2019) também avaliou o estado fresco de cimentos pozolânicos. Nesse trabalho foram avaliadas as propriedades reológicas de pastas de cimento contendo AC e fíler silícico. Segundo os autores foi observado que a incorporação de AC pode influenciar indiretamente o processo de hidratação do cimento levando até a uma hidratação adiantada do C_3A , atribuída ao efeito sinérgico entre a AC e o C_3A do cimento (ARAMBURO et al., 2019). Essa aceleração das reações acaba levando a um aumento da tensão de escoamento da mistura que pode chegar até ao dobro do valor do cimento comum (sem a incorporação de AC).

Amer e El-Hoseny (2017) avaliaram a influência da incorporação de AC a um cimento comum em propriedades como água necessária para consistência normal e tempos de início e fim de pega. Segundo este trabalho, a incorporação de AC a um cimento comum gera uma aceleração nos tempos de início e fim de pega (o que pode ser relacionado com o efeito de nucleação advindo do MCS) e um aumento na demanda por água para se atingir a consistência normal. Contudo, foi notado ainda que no caso das AC estudadas o teor de água demandada aumenta com a incorporação de MCS até o valor de 10% de AC no cimento e após isso passa a diminuir até o valor de 20% de substituição (limite estudado por Amer e El-Hoseny (2017)). A Figura 2.3 apresenta os resultados encontrados pelos autores.

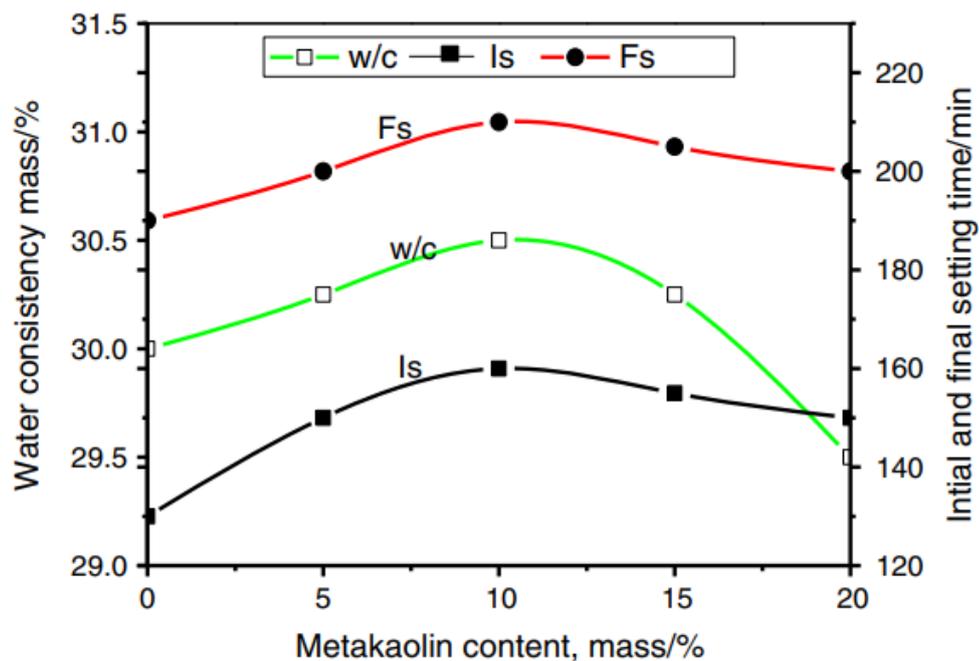


Figura 2.3 - Tempos de início e fim de pega e relação a/c para os diferentes teores de AC incorporadas (AMER e EL-HOSEN, 2017)

Dessa forma é possível notar que a incorporação de pozolanas pode também afetar o estado fresco de misturas cimentícias contendo esses MCS. Podendo vir a aumentar a demanda de água da mistura e variar propriedades como tensão de escoamento e tempos de pega. Tal afirmação vai de acordo com as observações de Mehta e Monteiro (2014) que afirmam que um dos principais fatores que controla o tempo de pega é a composição do cimento, ou seja, caso se acrescentem MCS em sua composição essas propriedades poderão ser variadas.

Já Antoni et al. (2012) realizou estudos com uma classe específica de AC, o Metacaulim (MK), e fíler calcário (FC) para estudo do cimento Portland. Foram produzidos os seguintes traços de argamassas: Referência, um com cimento comum (OPC), sem qualquer substituição; um cimento pozolânico, com substituição de 30% de cimento por MK (MK30); um cimento comum, com substituição de 15% de cimento por FC (LS15); um cimento composto (B15), com substituição combinada de 5% de FC e 10% de MK; um cimento composto (B30), com substituição combinada de 10% de FC e 20% de MK; um cimento composto (B45), com substituição combinada de 15% de FC e 30% de MK; e outro cimento composto (B60), com substituição combinada de 20% de FC e 40% de MK. Os resultados de resistência à compressão se encontram na Figura 2.4.

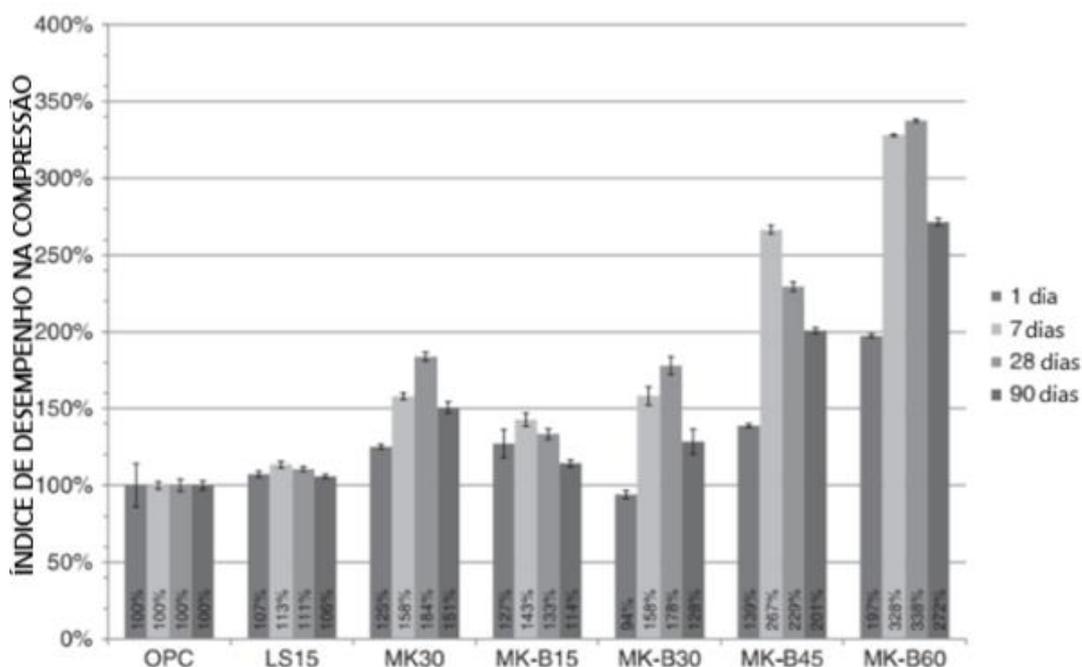


Figura 2.4 - Índice de desempenho na resistência à compressão, em relação às substituições equivalentes de fíler silícico (ANTONI et al., 2012)

Os índices de desempenho apresentados na Figura 2.4 estão todos normalizados em relação às misturas contendo seu respectivo teor total de substituição de MCS por Fíler Silícico (completamente inerte). Dessa forma, segundo Antoni et al. (2012) e Vasques (2019), a diferença entre o desempenho de cada um dos traços é atribuída apenas aos efeitos químicos provenientes de cada uma das misturas.

Nota-se inicialmente que todos os traços contendo MK apresentaram desempenho superior ao traço com cimento comum (OPC). Contudo, os traços B30, B45 e B60 se destacam com desempenhos muito mais elevados do que o MK30. Esse comportamento é justificado por Antoni et al. (2012) como proveniente do efeito sinérgico entre a AC e o FC, que quando combinados em teores adequados podem reagir e dando origem ao monocarboaluminato de cálcio e ao hemicarboaluminato, compostos que preenchem os vazios da microestrutura e garantem maior desempenho mecânico à mistura (ROCCHI e OLIVEIRA, 2017; CANBEK et al., 2022).

A partir dos traços B15, B30, B45 e B60 desse estudo se originou um novo tipo de cimento, o cimento LC3. Este cimento consiste basicamente na substituição de teores elevados de clínquer por uma combinação de FC e AC, que caso dosada adequadamente originará um cimento com desempenho mecânico igual ou superior ao CP comum (e à um

cimento pozolânico, segundo Rocchi e Oliveira (2017)) e com custo energético e ambiental inferior para a produtora de cimento. Seu nome, LC3, advém da sigla para *Limestone Calcined Clay Cement*, (cimento de fíler calcário e argila calcinada) e representa os componentes dessa nova classe de cimento.

O LC3 deve grande parte de seu potencial de uso à ocorrência das reações sinérgicas entre o FC e a AC. Essas reações ocorrem devido à presença de alumina nas AC e do Carbonato de Cálcio advindo do FC, estes compostos reagem juntamente com Hidróxido de Cálcio advindo da hidratação do C_3S e do C_2S presentes no clínquer dando origem aos carboaluminatos (ANTONI, 2012; LINS, 2017). Estes últimos compostos são responsáveis pelo refinamento da rede porosa do compósito, resultando em aumento do desempenho mecânico desse. Contudo, é importante ressaltar que para que a reação sinérgica seja otimizada é preciso que sejam adotados teores de substituição adequados de AC e FC, de forma a equilibrar a quantidade de reagentes para a formação dos carboaluminatos. Dessa forma fica claro que o comportamento do LC3 difere do comportamento de um cimento Pozolânico comum, isso em termos de desempenho mecânico e cinética de hidratação.

Devido a isso o LC3 tem sido alvo de pesquisas na atualidade, por ser um cimento pozolânico especial, com forte pegada ecológica. Seus materiais constituintes têm sido apontados como as futuras tendências para uso em misturas cimentícias (LINS, 2017, VISEDO e PECCHIO, 2019; TIRONI et al., 2019; VASQUES, 2019, CANBEK et al., 2022). A longo prazo, a incorporação de argilas calcinadas e fíler calcário ao cimento se tornará cada vez mais relevante, uma vez que estes contribuem para a redução da emissão de CO_2 na cadeia de produção do cimento (IEA, 2020).

Conforme apontado na Figura 2.4, o comportamento de um cimento LC3 difere do comportamento de um cimento pozolânico comum. Sabendo disso é importante salientar que o CPIV utilizado na pesquisa a ser desenvolvida possui teores de AC e FC, conforme já explicitado. Dessa forma, este possui certa similaridade com um LC3, porém seus teores de FC e AC não foram dosados pensando em um LC3 e por isso não apresentam a proporção que seria ideal para um cimento deste tipo, o que pode resultar em um compósito com desempenho intermediário entre um LC3 e um cimento pozolânico.

Dessa forma, embora o foco deste trabalho seja análise de um CPIV, é válido lembrar que a composição do cimento analisado permite que este seja caracterizando como um

cimento LC3. Devido a isso, no caso específico deste trabalho, pode ser possível atribuir comportamentos desse cimento aos efeitos e reações advindos desse novo tipo de cimento.

2.3 MACHINE LEARNING (ML)

Machine Learning (ML), ou em português Aprendizado de Máquina, é um ramo da área da Inteligência Artificial dedicado à criação de modelos capazes produzir respostas à novas situações através do aprendizado de situações passadas. Segundo Mueller, Kusne e Ramprasad (2016) o foco do ML é criar algoritmos que sejam capazes de aprender com um banco de dados existente e a partir destes classificar e prever futuras situações a partir de novos dados incorporados. Segundo Vakharia e Gujar (2019) as técnicas de ML são fortemente relacionadas com o reconhecimento de padrões e análises estatísticas computacionais.

Existem diversos tipos de técnicas de ML, porém todas trabalham com o mesmo objetivo: explorar o espaço amostral e encontrar padrões entre os dados disponíveis. Para isso é disponibilizado ao algoritmo um subconjunto de dados denominado Conjunto de Treinamento, o modelo será treinado neste espaço até que seja capaz de encontrar padrões entre os dados contidos neste (BULLARD et al., 2019). É válido ressaltar que os dados contidos no subconjunto de treinamento são denominados Dados de Treinamento. Após o fim do treinamento o modelo é testado e validado com o restante dos dados do conjunto total de dados a fim de se avaliar seu desempenho.

É importante definir os dois tipos de dados existentes quando se fala de ML: os dados de entrada (*inputs*) e dados de saída (*outputs*). Os *outputs* representam os valores que serão previstos pelo modelo, são a resposta que o algoritmo deve fornecer para cada situação apresentada. Já os *inputs* são os dados utilizados pelas técnicas de ML para se estimar os *outputs*. Idealmente um banco de dados elaborado para produção de um algoritmo de ML para predição de dados deve conter tanto os dados de *input* como seus respectivos dados de *output*, de forma que possam ser traçadas da forma mais eficiente possível as correlações entre estes parâmetros. Conhecendo estes conceitos pode-se chegar à conclusão de que o objetivo de um modelo de ML é conseguir prever *outputs* de forma mais acurada possível a partir dos *inputs* fornecidos.

Há duas classes principais de técnicas de ML, as de treinamento supervisionado e as de treinamento não supervisionado (MUELLER, KUSNE, RAMPRASAD; 2016), sendo que a

diferença entre estas classes está no Conjunto de Treinamento de cada uma. As técnicas supervisionadas possuem um Conjunto de Treinamento com dados de *input* e seus respectivos dados de *output*. Durante seu treinamento, essas técnicas objetivam identificar uma função que correlacione os dados de entrada com os de saída, a fim de que os futuros dados de *input* incorporados possam ser utilizados para prever novos *outputs*. Já as técnicas não supervisionadas tratam todos os dados do Conjunto de Treinamento como *inputs* (ou seja, não existem *outputs* nestas técnicas) e visam encontrar correlações entre os dados disponíveis nesse subconjunto (MUELLER, KUSNE, RAMPRASAD; 2016).

As técnicas de ML são altamente recomendadas para problemas de resolução complexa por meio dos métodos tradicionais que não apresentem algum algoritmo conhecido para resolvê-los. Segundo Oey et al. (2019) e Chaabene, Flah e Nehdi (2020), os tipos de técnicas de ML mais aplicados para estimar a resistência à compressão de materiais cimentícios são Artificial Neural Networks (ANN), Suport Vector Machine (SVM), Decision Trees (DT) e Random Forests (RF). Cada uma dessas classificações é capaz de analisar um banco de dados de forma diferente, gerando resultados com maior ou menor precisão a depender do tamanho desse conjunto de dados e dos parâmetros de entrada selecionados.

2.3.1 Artificial Neural Networks (ANN)

Os modelos de ML utilizando *Artificial Neural Network* (ANN) são baseados no funcionamento do cérebro humano, com relações não-lineares (REZA et al., 2019). Esse algoritmo consiste basicamente em diversos “nós” (denominados neurônios) conectados entre si que propagam as informações dos *inputs* por meio de séries de equações até que se chegue ao valor dos *outputs*, de forma similar ao que acontece nas redes neurais humanas. A Figura 2.5 apresenta um esquema do funcionamento das ANN.

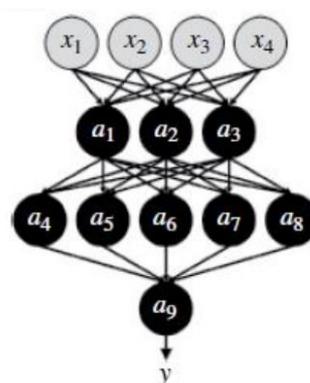


Figura 2.5 - Rede Neural multicamada (MUELLER, KUSNE, RAMPRASAD; 2016)

Analisando a Figura 2.5 pode-se perceber na parte superior uma primeira linha com valores de x_1 a x_4 (em cinza), estes são os *inputs* do sistema. Os dados de entrada são então direcionados à uma primeira camada de neurônios (A1 a A3 em preto), essa camada utiliza funções de ativação para calcular *outputs* que são então enviados para a segunda camada (A4 a A8), que utiliza esses dados gerados como novos *inputs* que novamente trata esses dados e gera um novo *output* que chega ao neurônio A9 que dá origem ao *output* final do modelo (valor Y).

O processo nas ANN pode ser repetitivo de camada para camada. No exemplo foi utilizado um pequeno número de camadas, porém há a possibilidade de se produzir modelos com mais de 100 camadas (CHAABENE, FLAH e NEHDI, 2020), ou gerando mais de um *output* final (MUELLER, KUSNE, RAMPRASAD; 2016) ou ainda uma rede com apenas uma camada, chamada de *perceptron*, conforme apresentado na Figura 2.6. De acordo com Mueller, Kusne e Ramprasad (2016), em um *perceptron* cada um dos *inputs* tem um peso que afeta a função de ativação do nó, dando origem ao *output* do modelo.

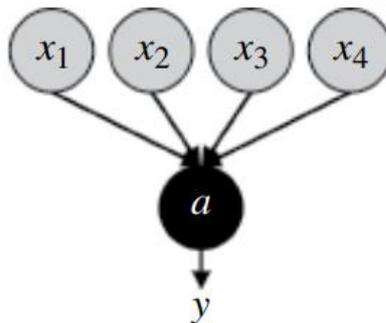


Figura 2.6 - Rede Neural – Perceptron (MUELLER, KUSNE, RAMPRASAD; 2016)

Este tipo de modelo de ML tem sido utilizado no campo da ciência dos materiais com considerável sucesso (MUELLER, KUSNE, RAMPRASAD, 2016; CHAABENE, FLAH e NEHD, 2020). Ainda segundo esses autores, as ANN já foram utilizadas para elaboração de modelos interatômicos, mapeamento do comportamento de materiais em fadiga, estudo de tratamento de materiais (à quente, deformações, congelamento) e também na previsão de propriedades de misturas cimentícias.

2.3.2 Decision Trees (DT)

Os modelos de *Decision Trees* (DT) remontam a alguns dos mais antigos tipos de ML, sendo historicamente a classe mais estudada, segundo Mueller, Kusne e Ramprasad (2016).

Este tipo de modelo é similar ao de ANN por também consistir em uma rede de nós, contudo no caso das DT um nó só pode estar conectado a um único nó anterior, conforme ilustrado na Figura 2.7. Ou seja, um nó pai pode dar origem a diversos nós filhos, assim como nos modelos de ANN, porém cada nó filho possui apenas um nó Pai, o que difere dos modelos de *Artificial Neural Networks*.

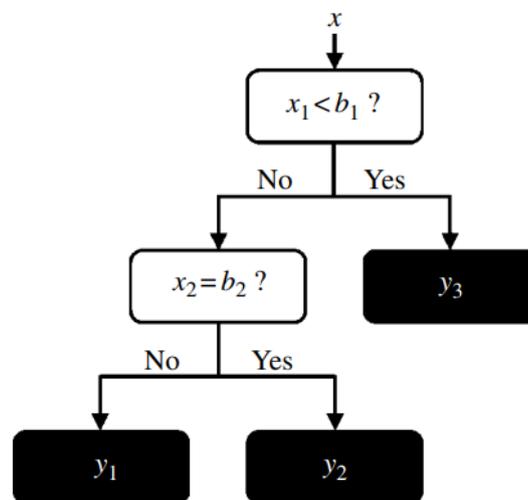


Figura 2.7 - Modelo de Decision Tree (MUELLER, KUSNE, RAMPRASAD; 2016)

Os modelos de DT operam por meio de uma avaliação do conjunto de dados em cada nó com o objetivo de classificar os dados em subconjuntos com o foco final de se classificar toda a amostra. No caso do uso de DT para previsão ou regressão de dados no local de uma classificação nos nós finais, se encontram valores numéricos (MUELLER, KUSNE e RAMPRASAD; 2016).

Em um modelo de DT a avaliação do banco de dados é iniciada a partir de um nó inicial, o Nó Raiz, sendo este o nó mais superior na Figura 2.7. A partir deste ponto os dados são analisados por nós subsequentes até que se atinja algum dos chamados Nós Folhas (Nós em preto na figura), ou seja, um nó sem ramificações. Cada nó pode dar origem à diferentes outros nós subsequentes, conforme pode ser observado na Figura 2.7, contudo o caminho a ser seguido em cada nó é definido de acordo com o valor de uma das variáveis (um dos valores de *input*) analisadas. Segundo Mueller, Kusne e Ramprasad (2016), diversas árvores diferentes podem prever um parâmetro a partir do mesmo Conjunto de Treinamento, contudo o modelo de DT com maior eficiência geralmente é o que apresenta menor caminho entre os nós raiz e folha.

2.3.3 Random Forest (RF)

Os modelos de *Random Forest* (RF) são uma categoria específica de modelos de DT. Os algoritmos de RF são versões otimizadas com capacidade de previsão mais potente em relação aos algoritmos de DT.

Os modelos de RF consistem na combinação de diversas DT diferentes de forma aleatória, cada uma treinada com um Conjunto de Treinamento diferente (HAN et al., 2019). Cada um desses conjuntos na verdade é uma subdivisão do Conjunto de Treinamento original do banco de dados, conjunto esse que deve ser dividido de forma aleatória com dados independentes. Cada árvore então é treinada independentemente, e os novos dados de *input* são repassados pelas árvores, com o *output* sendo uma média (MUELLER, KUSNE e RAMPRASAD; 2016) desses valores.

Diversos autores vêm utilizando técnicas de RF para prever propriedades de materiais, como Han et al. (2019), Mangalathu et al. (2018) e Zhang et al. (2019). É importante ressaltar que é consenso na literatura que o desempenho dos algoritmos de RF é maior e mais acurado do que o das árvores individuais que os compõem (MUELLER, KUSNE e RAMPRASAD, (2016); CHAABENE, FLAH e NEHDI, (2020)).

2.3.4 Aplicações de Machine Learning em Materiais Cimentícios

Atualmente técnicas de Machine Learning (ML) vêm sendo estudadas como uma alternativa para previsão do comportamento de misturas cimentícias. Behnood et al. (2015), Young et al. (2019) e Konstantopoulos et al. (2020) já utilizaram diferentes técnicas para prever propriedades de concretos como resistência à compressão aos 28 dias, resistência à tração, módulo de elasticidade do material entre outras. Já Asteris et al. (2021) e Kumar e Naranje (2020) desenvolveram pesquisas prevendo propriedades de cimentos por meio do ML.

Oey et al. (2019) utilizaram diferentes técnicas de RF para prever a resistência à compressão e o tempo de início de pega de cimentos Portland. Foram utilizadas propriedades físico-químicas do cimento como *inputs*, sendo estas: composição química (percentual de óxidos); teor de CaO livre; teor de MgO livre; teor de Perda ao Fogo; teor de água para consistência normal da pasta de cimento; tempo de fim de pega; e finura Blaine. É válido ressaltar que todos os dados foram obtidos com ensaios seguindo os parâmetros da ASTM a fim de uniformizar o banco de dados. Contudo os resultados obtidos apresentaram R^2

relativamente baixo, com valor de 0,582, o que foi atribuído pelos autores como relativo à um banco de dados com grande variedade de dados e baixa quantidade de conjuntos. Entretanto, é afirmado que com uma escolha melhor dos dados a serem utilizados no banco de dados e possível incorporação de mais dados as técnicas de RF se tornam muito mais eficientes (OEY et al., 2019).

Já Cook et al. (2021) utilizou modelos de RF para prever a taxa de liberação de calor e a liberação acumulada de calor durante a hidratação de cimentos Portland compostos. Foram utilizados 8 *inputs*, sendo estes: tipo de MCS utilizado; teor de cimento utilizado; conteúdo de aditivo superplastificante tipo 1; conteúdo de aditivo superplastificante tipo 2; superfície específica do CP; superfície específica do aditivo tipo 1; superfície específica do aditivo tipo 2; e tempo (em horas). Vale ressaltar que o banco de dados adotado consistia em 312 conjuntos de dados. Segundo Cook et al. (2021) as técnicas de RF garantiram uma previsão otimizada dos dados contínuos (como a taxa de liberação de calor) e acumulados (calor acumulado) ao longo do tempo. Os autores reforçam que o uso de técnicas de ML para este fim torna todo o processo de definição muito mais rápido do que o atual que usa modelos cinéticos numéricos.

Similarmente, Al-Hasany et al. (2023) utilizaram algoritmos de ML de Regressão Gaussiana para prever a taxa de liberação de calor durante a hidratação de cimentos Portland. O modelo desenvolvido foi projetado com dados de pastas de cimento contando MCS pozolânicos como escórias e cinza volante. Os *inputs* adotados englobavam dados como o tipo de MCS utilizado, tipo de cimento adotado, teor de substituição de cimento por MCS, relação água-sólidos, e temperatura de teste. Foram obtidos valores de R^2 próximos de 0,97, indicando correlação elevada entre os valores reais e previstos pelo modelo.

No âmbito de propriedades mecânicas, Kumar e Naranje (2019) produziram um modelo de ML utilizando ANN para prever a resistência à compressão de cimentos Portland nas idades de 2, 7 e 28 dias. Foram utilizados como *inputs*: teores de óxidos em massa; teor de Perda ao Fogo; finura Blaine; dados granulométricos do cimento; densidade do clínquer; dados granulométricos; umidade; Fator de Saturação de CaO; entre outros totalizando 17 *inputs*. O banco de dados utilizado para o modelo foi fornecido por uma cimenteira, totalizando um espaço amostral de 280 conjuntos de dados, onde 70 destes foram usados como treinamento e os demais para validação. O modelo foi criado utilizando a linguagem *python* e segundo Kumar e Naranje (2019) apresentou resultados razoáveis e próximos dos

resultados experimentais, gerando uma forma mais rápida e econômica de descobrir a resistência à compressão do cimento produzido pela indústria em questão.

Chaves (2021) efetuou previsões da resistência a 28 dias de cimentos Portland Tipo I (cimento comum) por meio de técnicas de ML. Foi utilizada a técnica de RF e efetuadas previsões em uma base de dados montada a partir de dados encontrados na literatura. A autora utilizou como *inputs* dados de caracterização físico-química, inclusive teores de óxidos dos cimentos analisados. Foram obtidos R^2 de 0,65 e RMSE de 4,50 MPa na etapa de treinamento.

Técnicas de ML também foram utilizadas em compósitos cimentícios com adições de materiais como nanotubos e outros nanomateriais. Huang et al. (2021) elaborou modelos de ANN e *Support Vector Machine* (SVM) para prever a resistência à compressão e à flexão de compósitos contendo nanotubos de carbono. Foi utilizado um banco de dados montado com dados adquiridos na literatura encontrada pelos autores com 114 conjuntos de dados, cada conjunto possuindo 2 *outputs* (resistências à flexão e compressão) e 9 *inputs*, sendo estes: relação a/c; tipo de cimento; propriedades dos MCS; tempo de cura; temperatura de cura; e método de dispersão. Ambas as técnicas utilizadas foram comparadas com métodos tradicionais de regressão pelos autores, onde se chegou a constatação de que os métodos de ML são mais eficientes do que os métodos de regressão.

Zhang et al. (2022) utilizou diferentes técnicas de ML para prever a resistência à compressão de cimento com MCS alternativos. São usadas 6 técnicas diferentes (apresentadas na Tabela 2.3) para prever o comportamento mecânico da mistura cimentícia e avaliar quais das variáveis utilizadas como *inputs* apresentam maior influência na resistência à compressão do material. Segundo os autores as técnicas de *Ensemble Regression* e *Convolutional Neural Network* apresentaram o melhor desempenho entre as analisadas.

Já Marani e Nehdi (2020) elaboraram diversos modelos de ML para avaliar a resistência à compressão de compósitos contendo PCMs. Foram utilizados modelos como os de RF, *Extra Trees* e *Gradient Boosting* em um universo amostral de 154 conjuntos de dados (10 *inputs* e 1 *output* cada) para realizar as previsões. Os *inputs* adotados foram: teor de adições; tipo de cimento; relação a/c; teor de agregado miúdo; teor de agregado graúdo; teor de superplastificante; idade; temperatura de teste; calor latente do PCM. Todos os algoritmos produzidos por Marani e Nehdi (2020) apresentam valores de R^2 acima de 0,93 e foram

declarados como eficientes, sendo o modelo de *Gradiente Boosting* o com melhor desempenho. Os autores ainda ressaltam a importância de se conhecer as relações teóricas entre as propriedades disponíveis para se melhor definir quais devem ser inseridas como *inputs* e quais podem ser descartadas.

Sevim et al. (2022) realizou previsões de resistência à compressão de cimentos pozolânicos (com cinza volante) utilizando dois tipos diferentes de algoritmos de ML. Foi utilizado um banco de dados com 196 amostras geradas experimentalmente e utilizados algoritmos de ANN e Adaptive-Network Based Fuzzy Interference Systems (ANFIS). Sevim et al. (2022) foi um dos poucos autores que utilizou teores de óxidos como um dos *inputs* em seu algoritmo. Segundo os autores o modelo ANFIS apresentou melhor desempenho em relação ao modelo de ANN elaborado.

Bansal et al. (2022) também utilizou técnicas de ML para prever a resistência à compressão de cimentos Portland comuns, pozolânicos (com cinza volante) e do tipo LC3. Foram utilizadas diferentes variações de técnicas de Regressão Linear e SVM. O diferencial dessa pesquisa, entretanto, foi a utilização de dados piezométricos como *inputs* para alimentação dos algoritmos (como valores relativos à impedância mecânica). Essa abordagem resultou em algoritmos com elevado grau de correlação entre previsão e valores reais (valores de R^2 próximos a 0,99) para todos os 3 tipos de misturas cimentícias analisadas.

Turk et al. (2023) também elaborou modelos de ML para prever a resistência à compressão de misturas cimentícias com MCS. Foram utilizados algoritmos de Extreme-ML, ANN, SVM e DT para prever valores de resistência à compressão e à tração na flexão com 28 e 91 dias de idade de argamassas auto adensáveis. Foram adotados *inputs* como relação água-aglomerante, idade de rompimento, teor de areia e teor de cada um dos MCS adotados. Após uma análise de mais de 300 conjuntos de dados se obtiveram modelos com valores de R^2 acima de 0,96 na previsão de resistência à compressão para todos tipos de algoritmos, com exceção do modelo utilizando SVM que apresentou R^2 de 0,633. Segundo os autores, o modelo com maior acurácia e melhor desempenho foi o de Extreme-ML que pode ser utilizado para previsões em argamassas auto adensáveis, concretos e argamassas convencionais. Tal fato já aponta para a evolução do ML no campo da construção civil, onde classes de algoritmos mais robustas tem sido desenvolvidas (como o Extreme-ML) a fim de se gerar previsões cada vez mais confiáveis.

Fica claro que há uma tendência de se estudar as aplicações de ML em CP compostos. Como já apresentado há pesquisas com CP pozolânicos, misturas ternárias e até com aditivos especiais como PCM.

Seguindo essa linha, Asteris et al. (2021) utilizou técnicas de ML para prever a resistência à compressão de cimentos pozolânicos (com uso exclusivo de MK). Foi utilizado um banco de dados com 424 conjuntos de dados montado pelos autores com dados da literatura disponível, utilizando como *inputs* dados como: tipo de cimento; idade de rompimento; relação a/c; quantidade de aditivo superplastificante utilizado; teor de MK incorporado; e teor de areia utilizado. Os autores analisaram o banco de dados utilizando técnicas de SVM, DT, RF, AdaBoost e *K-nearest neighbours* para prever a resistência à compressão do cimento.

Segundo Asteris et al. (2021) as técnicas com melhores acurácias para previsão da resistência à compressão são as de AdaBoost e RF. Foi utilizado o padrão R^2 para ranquear os modelos utilizados, sendo que o algoritmo de RF obteve um valor de 0,9439 para a fase de testes e o AdaBoost apresentou valor de 0,9768 para esta mesma etapa. Já o algoritmo com menor valor de R^2 entre os avaliados pelos autores foi o de SVM com valor de 0,4203 para a etapa de teste.

O cimento utilizado por Asteris et al. (2021) pode ser classificado como um cimento pozolânico, sendo este muito similar ao utilizado nesta pesquisa. Segundo Asteris et al. (2021), as técnicas tradicionais de previsão de propriedades de misturas cimentícias (como a resistência à compressão) não são eficientes quando estas misturas possuem incorporação de pozolanas. Isso porque misturas cimentícias pozolânicas apresentam um elevado número de componentes constituintes, o que dificulta o processo de previsão analítica das propriedades dessas misturas. Além disso, muitas vezes as interações entre os componentes do cimento pozolânico analisados ocorrem de forma não-linear (BEN CHAABENE et al., 2020), dificultando ainda mais o processo de previsão por técnicas tradicionais e analíticas. Tudo isso justifica a necessidade do uso de técnicas como o ML para se prever o comportamento de misturas com MCS pozolânicos.

A Tabela 2.3 a seguir apresenta um resumo de parâmetros encontrados por diversos autores ao prever a resistência aos 28 dias do cimento Portland por meio de diferentes técnicas de ML.

Tabela 2.3 - Modelos de ML propostos na Literatura para previsão de resistência à compressão aos 28 dias de cimentos Portland

Autor	Ano de Publicação	Algoritmos Adotados	Parâmetros de Treinamento		Parâmetros de Teste			Parâmetros dos Algoritmos		
			R ²	RMSE	R ²	RMSE	MAPE	Erro Médio absoluto (MAE)	Número de <i>Inputs</i>	Número de Conjuntos de Dados
Shi e Dong	2011	ANN			0,908	1,220			7	34
		SVM			0,958	0,800				
Oey et al.	2019	Linear Regression (RL)			0,305	4,010	7,06		20	2211
		K-NN			0,394	3,770	6,35			
		Bagged Trees			0,489	3,500	5,91			
		RF			0,497	3,480	5,87			
		Extra Trees			0,506	3,440	5,79			
Kumar et al.	2020	ANN			0,681			2,3607	16	304
		RF			0,939	3,988				
		Extra Trees			0,957	3,373				
Marani et al.	2020	Gradient Boosting			0,977	2,419			10	154
		Extreme Gradient Boosting			0,969	2,845				
Asteris et al.	2021	KNN	0,881	7,527	0,874	7,789			6	424
		SVM	0,379	17,736	0,420	17,667				
		RF	0,977	3,359	0,944	5,240				
		DT	0,819	9,256	0,853	8,439				
		AdaBoost	0,997	1,305	0,947	5,291				

Chaves	2021	RF	0,93	0,65	0,65	4,50		15	104
Ma et al.	2021	SVM			0,941	0,332		4	144
		DT			0,925	0,240			
		RF			0,947	0,229			
Huang et al.	2021	ANN	0,770	9,741	0,848	7,475		9	114
			0,785	9,651	0,848	7,472			
			0,787	9,622	0,846	7,522			
			0,796	9,464	0,848	7,467			
			0,791	9,579	0,848	7,468			
			0,776	9,688	0,848	7,472			
		ANN	0,924	5,850	0,894	7,080	48,6		
Sevim et al.	2021	Adaptive network Based Fuzzy Interference Systems (ANFIS)	0,936	5,341	0,946	5,106	30,3	3	150
Abidin et al.	2022	Extreme Machine Learning	0,994	1,127	0,970	2,522		4	60
		SVM	0,982	1,980	0,982	1,970			
		Group Method of Data Handling	0,990	1,490	0,969	2,335			
Adel et al.	2022	DT	0,982	2,205	0,869	5,859	0,0798	10	276
		RF	0,983	2,152	0,916	4,682	0,066		
		AdaBoost	0,970	2,852	0,913	4,804	0,069		
		Gradient Boosting	0,999	0,327	0,934	4,120	0,055		
		XGBoost	0,996	0,986	0,939	3,998	0,054		

Alkadhim et al.	2022	Gradient Boosting			0,930	5,480	4,41	6	36
		RF			0,940	1,460	1,49		
Gayathri et al.	2022	Linear Regression	0,460	15,968	0,480	15,282	11,27	6	424
		RF	0,990	2,145	0,970	3,640	2,38		
		SVM	0,950	5,104	0,930	5,499	3,19		
		AdaBoost	0,840	8,813	0,780	9,841	7,95		
		Multi-layer perceptron	0,840	8,799	0,900	6,843	4,69		
		Gradient Boosting	0,990	1,865	0,980	3,332	2,31		
		DT	1,000	1,463	0,940	5,108	3,23		
hist gradient boosting	0,950	4,836	0,970	3,500	2,43				
Huang et al.	2022	XGBoost	1,000	1,493	0,970	3,354	2,00	5	361
		RF+Firefly Algorithm	0,704	11,143	0,697	11,664			
Li et al.	2022	Linear Regression (RL)	0,820	6,700	0,650	8,600	6,4	12	253
		SVM	0,960	3,400	0,850	5,600	4,1		
		RF	0,980	1,900	0,910	4,500	3,4		
		XGBoost	0,980	2,300	0,940	3,500	2,6		
Shanmugasundaram et al.	2022	ANN			0,936		13	1157	

		Linear Regression	0,800	5,080	4,38		
		SVM	0,980	1,720	1,36		
		RF	0,980	1,380	0,98		
Zhang et al.	2022	ANN	0,950	2,530	2,09		
		Ensemble Regression	0,990	1,310	1	6	317
		Convolutional neural network Regression	0,990	1,180	0,8		

		LR	0,93	4,13	3,6		
		Robust LR	0,93	4,14	3,56		
Bansal et al.	2022	Stepwise LR	0,96	3,42	2,76		
		SVM	0,93	4,2	3,48	5	8040

Quadratic SVM	0,98	2,5	2,01
Cubic SVM	0,99	1,59	1,38
Fine Gaussian SVM	0,99	1,92	1,864
Medium Gaussian SVM	0,99	1,93	1,66
Coarse Gaussian SVM	0,95	3,53	2,88

Extreme-ML	0,985	3,267	0,980	1,913	5,118
SVM	0,740	8,069	0,633	8,983	46,822
ANN	0,942	3,779	0,964	3,717	11,978
DT	0,985	1,934	0,968	3,092	11,469

Turk et al. 2023

6

25

3 METODOLOGIA

Neste item foi detalhada a metodologia proposta para o estudo em questão, que visa prever a resistência à compressão do cimento Portland Pozzolânico - Tipo IV (CPIV) utilizando técnicas de *Machine Learning* por meio de diferentes bancos de dados. A Figura 3.1 apresenta o Fluxograma da metodologia proposta, que está dividida em 3 etapas a serem detalhadas neste capítulo: 1 - Tratamento de Dados e Montagem de Bancos de Dados; 2 - Treinamento e Teste dos Algoritmos; 3 – Comparação de Resultados entre Modelos A e B.

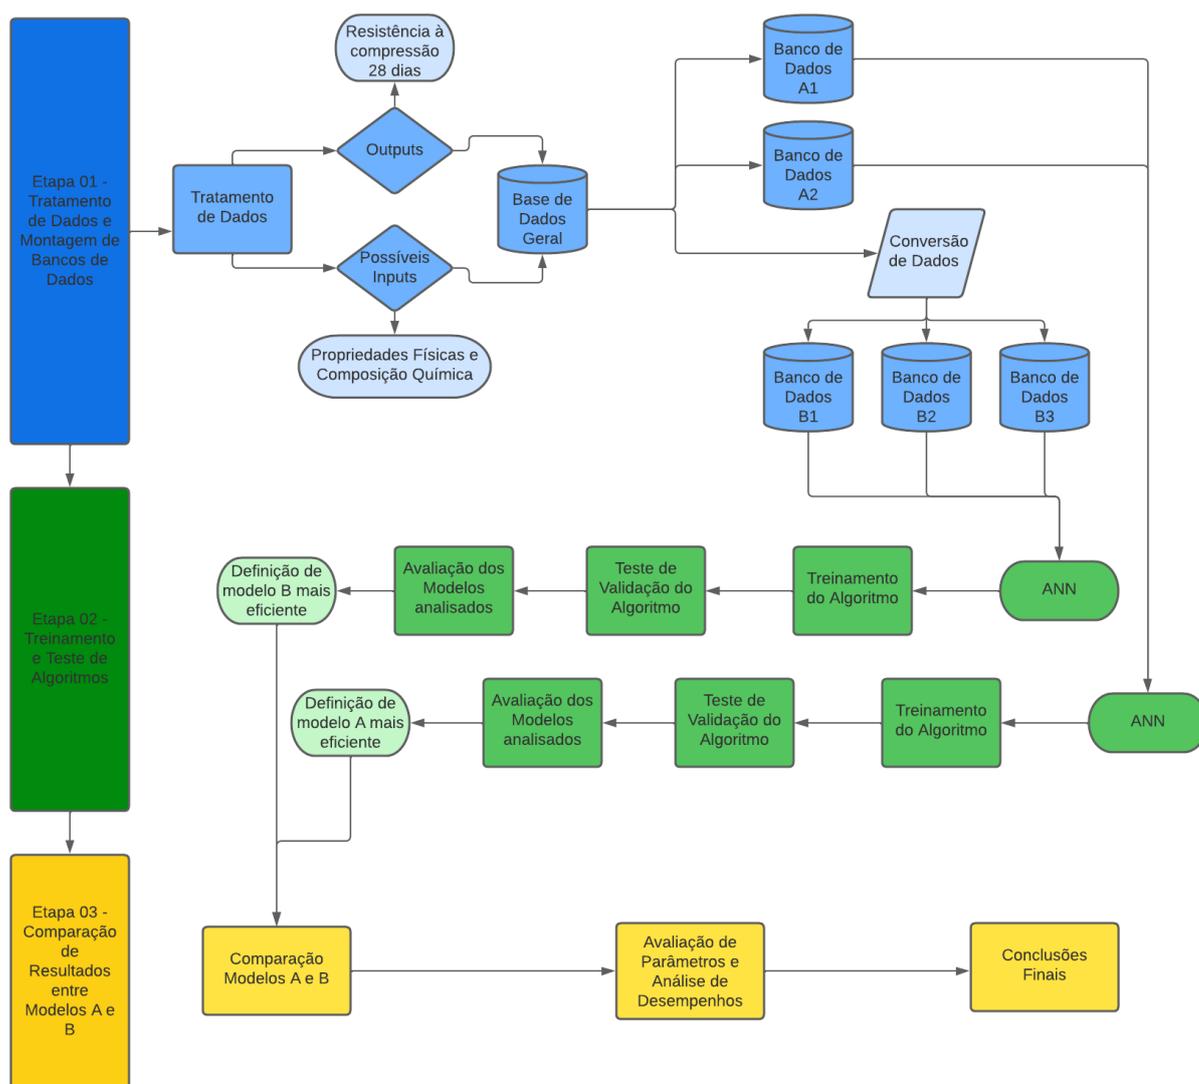


Figura 3.1 - Fluxograma geral da metodologia de pesquisa

3.1 ETAPA 01- TRATAMENTO DOS DADOS FORNECIDOS E MONTAGEM DE BANCOS DE DADOS

A Etapa 1 consiste na triagem e tratamento dos dados fornecidos pela cimenteira e a subsequente montagem de uma Base de Dados Geral que foi utilizada para confecção de diferentes bancos de dados para o treinamento e teste dos algoritmos elaborados. A indústria cimenteira forneceu relatórios de avaliação da qualidade do CPIV produzido, conforme apresentado no modelo apresentado na Figura 3.2. Estes relatórios são produzidos periodicamente (uma produção média de 15 relatórios por mês) na empresa em questão, a fim de se averiguar a qualidade do cimento fabricado e se este atende aos critérios normativos estipulados pelas normativas vigentes.

CIMENTO		Abril / 2021										QUALIDADE			
Ensaio (u.m.)	Resistência à Compressão (Mpa)				Ensaio Físicos					Ensaio Químicos					
	01 Dia	03 Dias	07 Dias	28 Dias	Granulometria (%)	Blaine (cm ² /g)	Água Consist. (%)	Início de pega (min)	Fim de pega (min)	Gravimetria (%)		FRX (%)			Adições
Data da Coleta					#200					PF	RI	SO ₃	MgO	Alcalis Tot	% Pozolana
Máx NBR 16697	-	-	-	-	8,0	-	-	-	-	6,5	-	4,0	5,0		50,0
03/04/2021	12,36	25,85	35,54	43,84	4,60	5511	33,40	135	225	3,79	25,93	4,03	4,24		26,73
06/04/2021	12,58	26,10	38,81	44,06	4,83	5520	33,60	130	220	3,90	25,56	3,89	4,23		26,35
07/04/2021	12,28	26,33	37,01	43,33	4,54	5637	33,60	130	220	3,84	25,16	3,93	4,25		25,94
08/04/2021	12,70	26,52	38,50	44,78	4,11	5578	33,40	140	240	3,69	26,42	4,52	4,14		27,24
10/04/2021	12,23	27,07	38,76	44,76	4,20	5562	33,40	135	225	3,80	25,02	3,82	4,38		25,79
13/04/2021	12,52	27,52	37,22	43,43	4,60	5551	33,50	135	220	4,35	22,64	4,06	4,23		29,40
15/04/2021	12,10	29,18	37,03	44,73	4,76	5532	33,40	130	220	4,63	22,54	4,26	4,24		29,27
18/04/2021	11,59	28,66	36,63	44,62	4,80	5638	33,00	135	230	4,86	22,34	3,90	4,17		29,01
19/04/2021	11,39	30,17	36,24	43,48	4,74	5747	33,00	140	230	5,00	21,00	3,99	4,12		27,27
20/04/2021	12,66	30,37	35,94	44,34	4,70	5674	32,00	135	235	4,48	22,36	4,32	4,19		27,95
24/04/2021	13,03	30,80	36,81	43,81	4,68	5850	32,20	140	245	4,35	23,70	3,50	4,22		29,63
27/04/2021	12,99	26,89	36,49	43,70	4,86	5641	31,80	120	220	4,25	23,92	3,85	4,17		29,90
29/04/2021	13,64	27,63	36,52	43,90	4,91	5869	32,00	130	220	4,20	23,50	3,34	4,28		29,38
Min.	11,4	25,9	35,5	43,3	4,1	5.511	31,8	120	220	3,7	21,0	3,3	4,1	0,0	25,8
Méd.	12,5	27,9	37,0	44,1	4,6	5.639	32,9	133	226	4,2	23,9	4,0	4,2		28,0
Máx.	13,6	30,8	38,8	44,8	4,9	5.869	33,6	140	245	5,0	26,4	4,5	4,4	0,0	29,9
D.Pad.	0,6	1,7	1,0	0,5	0,2	119	0,7	5	8	0,4	1,7	0,3	0,1		1,5

Obs: Resultados R3, R7 e R28 em branco aguardando data exata para rompimento. Cimentos expedidos aos sábados estão compostos na média expedida da sexta-feira anterior.
Massa específica = 2,97 g/cm³

Figura 3.2 - Relatório de Qualidade do cimento CPIV (Fornecido pela indústria cimenteira)

3.1.1 TRATAMENTO DOS DADOS FORNECIDOS

Entre os dados fornecidos pela cimenteira nos relatórios periódicos se apresentam: resistência à compressão aos 1, 3, 7 e 28 dias nos parâmetros da norma NBR 7215 (ABNT, 2018); Finura na peneira 75; Finura Blaine; água necessária para se atingir a consistência normal; tempos de início e fim de pega; teores de perda ao fogo; teores de resíduo insolúvel; teores de óxidos advindos de ensaios de Fluorescência de Raio-X (FRX); e teor de pozolana incorporada (a saber, argila calcinada). Todos esses parâmetros são obtidos pela cimenteira a partir dos procedimentos detalhados a seguir.

3.1.1.1 OBTENÇÃO DE PARÂMETROS PELA CIMENTEIRA

Os dados de resistência à compressão são obtidos por meio dos ensaios normatizados pela NBR 7215 (ABNT, 2018). Segundo esse parâmetro são produzidos corpos de prova cilíndricos (com traço e teor de a/c pré-definidos) que são submetidos a testes de compressão

em cada idade (1, 3, 7 e 28 dias) a fim de se avaliar o desempenho mecânico do cimento produzido, sempre seguindo todos os parâmetros de ensaio, cura e produção de amostras definidos pela norma.

Os dados de granulometria (finura Blaine e finura na peneira 75) são obtidos após a produção do cimento CPIV segundo os critérios das normas NBR 16372 (ABNT, 2015) e NBR 11579 (ABNT, 2012) respectivamente.

Já os valores de água necessária para consistência normal e tempos de início e fim de pega são obtidos por meio dos procedimentos detalhados na NBR 16606 (ABNT, 2018) e NBR 16607 (ABNT, 2018). A pasta de consistência normal é aquela que apresenta comportamento predefinido em sua respectiva norma (NBR 16606). Esse tipo de massa é utilizado normativamente (segundo a NBR 16607) para se definir os tempos de início e fim de pega por meio do aparelho de Vicat.

O teor de resíduo insolúvel é obtido por meio dos procedimentos detalhados na norma NBR NM 15 (ABNT, 2012) e o teor de perda ao fogo pelo padrão estabelecido pela NBR NM 18 (ABNT, 2012). Tais valores são utilizados como parâmetros para liberação ou não para comercialização de cada tipo de classe de cimento Portland no Brasil pela NBR 16697 (ABNT, 2018).

O teor de pozolana incorporada (argila calcinada) é medido durante a fabricação do cimento CPIV. Após o processo de fabricação do clínquer e adição de gipsita, são incorporados teores adequados de argila calcinada de acordo com os parâmetros de produção utilizados pela cimenteira. Esses teores são controlados e registrados pelos profissionais da empresa.

Por fim, os teores de óxidos do cimento Portland são obtidos por meio de análise de ensaio FRX. No caso específico da cimenteira analisada são monitorados os seguintes óxidos:

- CaO;
- SiO₂;
- Al₂O₃;
- Fe₂O₃;

- MgO;
- SO₃;
- K₂O;
- Na₂O.

É possível notar que na Figura 3.2 não são apresentados os resultados completos de FRX. Contudo, estes foram fornecidos em planilha separada (em formato XLSX) pela empresa e ao longo do processo de tratamento dos dados foram compilados juntamente aos demais dados em planilha XLS. Ressalta-se ainda que os dados de FRX são de extrema importância para o estudo, uma vez que permitem avaliar a composição química do CPIV analisado (com destaque para os teores de CaO, SiO₂, Fe₂O₃ e Al₂O₃), de forma a melhor caracterizar a amostra.

3.1.1.2 TRATAMENTO DOS DADOS E MONTAGEM DA BASE DE DADOS GERAL

Foram fornecidos pela cimenteira os dados referentes a janeiro de 2019 até junho de 2021 de produção de CPIV para a produção da Base de Dados Geral (BDG). Todos estes dados foram compilados manualmente em uma planilha (em formato XLSX) contendo os valores de *inputs* e *outputs* para cada amostra avaliada. Após o tratamento dos dados para eliminação de possíveis valores duplicados, conjuntos incompletos ou vazios e outliers, foi produzido um universo de 309 amostras a serem analisadas, sendo que cada amostra é composta por 20 parâmetros que caracterizam o CPIV, sendo estes:

- Resistências à compressão com 1 dia;
- Resistência à compressão aos 3 dias;
- Resistência à compressão aos 7 dias;
- Resistência à compressão aos 28 dias;
- Tempo de Início de Pega;
- Tempo de Fim de pega;
- Teor de água necessário para se atingir a Consistência Normal;

- Teores de óxidos obtidos através de ensaios de FRX de: CaO, SiO₂, Al₂O₃, Fe₂O₃, MgO, SO₃, K₂O e Na₂O;
- Teor de Resíduo Insolúvel;
- Teor de Perda ao Fogo;
- Superfície Específica Blaine;
- Finura na peneira 0,075 mm;
- Teor de pozolana adicionado à mistura;

Os dados fornecidos foram divididos em duas categorias diferentes: *possíveis inputs e outputs*. Os primeiros consistem nos dados que poderão ser utilizados para alimentar o algoritmo desenvolvido, são os dados de entrada para o treinamento do programa. Já os *outputs* são os dados que correspondem aos valores buscados pelo algoritmo, ou seja, são a resposta que o programa deve produzir a partir dos dados de *input*, no caso apenas o parâmetro “resistência à compressão aos 28 dias” foi definido como *output*. Desse modo foi montada a Base de Dados Geral (BDG) que foi utilizada para se montar os 5 diferentes bancos de dados que serviram aos 5 diferentes algoritmos elaborados.

A planilha elaborada contendo todos os parâmetros da BDG está apresentada no Apêndice A deste trabalho.

3.1.2 MONTAGEM DOS BANCOS DE DADOS

Nessa pesquisa um dos focos é a comparação entre diferentes parâmetros em relação à composição química que podem ser utilizados para se prever a resistência aos 28 dias do cimento Portland pozolânico. Desse modo foram elaborados algoritmos de duas categorias diferentes, a primeira (tipo A) que utiliza teores de óxidos para realizar previsões da resistência do cimento; e segunda (tipo B) que utiliza teores de compostos principais do cimento Portland para realizar esse mesmo tipo de previsão. Para cada uma dessas classes é necessário que seja montado um banco de dados diferente uma vez que o que diferencia esses algoritmos é justamente o tipo de *input* que utilizam.

Assim a BDG foi utilizada para se produzir os diferentes tipos de Bancos de Dados necessários para os 5 algoritmos estudados. Nessa etapa serão detalhados os processos para cada um desses casos.

3.1.2.1 ANÁLISE DE PARÂMETROS DISPONÍVEIS

Antes da montagem dos bancos de dados foi necessário se avaliar a correlação e o comportamento das variáveis disponíveis na BDG. Dessa forma foi iniciada uma análise exploratória dos dados a fim de se avaliar as medidas gerais (média, desvio padrão, dispersão) dos dados disponíveis, servindo como um indicativo das possíveis variáveis a se utilizar como *inputs* para a previsão da resistência à compressão do CPIV aos 28 dias. Após essa análise foram selecionadas variáveis para a montagem de cada um dos Bancos de Dados de acordo com os resultados obtidos.

Os dados candidatos a serem adotados como *inputs* no BDG para a previsão da resistência à compressão aos 28 dias são: os teores de óxidos fornecidos pelo ensaio de FRX; a finura Blaine; finura na peneira 0,075mm; teores de perda ao fogo e resíduo insolúvel, teores de pozolana e resistências à compressão aos 1, 3 e 7 dias. Vale apontar que a relação água-cimento (*a/c*) não foi utilizada como um *input* por esta ser a mesma para todas as amostras (valor de 0,48 conforme dita a NBR 7215).

3.1.2.2 MONTAGEM DOS BANCOS DE DADOS TIPO A

Os Bancos de Dados tipo A foram utilizados por algoritmos que visam prever a resistência à compressão do CPIV por meio dos seus teores de óxidos. Como já explicitado anteriormente, esses teores foram obtidos por meio dos resultados de ensaios de FRX.

No caso dessa análise, utilizando teores de óxidos, foram montados dois bancos de dados, para a avaliação de dois diferentes algoritmos. A primeira base de dados, Banco de Dados A1, consiste em um banco de dados que entre seus *inputs* apresenta o parâmetro Resistência à Compressão com 1 dia de idade; já o segundo banco, o Banco de Dados A2, não apresenta esse parâmetro como *input* sendo essa a única diferença que possui em relação ao primeiro banco de dados mencionado. Dessa forma se tornará possível avaliar a influência específica do uso do *input* “Compressão a 1 dia” na previsão da resistência à compressão aos 28 dias, conforme pode ser observado na Tabela 3.1.

Tabela 3.1 - Inputs nos bancos de dados tipo A

Inputs	Base de Dados A1	Base de Dados A2
Material passante na peneira #200 (%)	Sim	Sim
Finura Blaine (cm ² /g)	Sim	Sim
Perda ao Fogo (%)	Sim	Sim
Resíduo Insolúvel (%)	Sim	Sim
Argila Calcinada (%)	Sim	Sim
CaO (%)	Sim	Sim
SiO ₂ (%)	Sim	Sim
Al ₂ O ₃ (%)	Sim	Sim
Fe ₂ O ₃ (%)	Sim	Sim
MgO (%)	Sim	Sim
SO ₃ (%)	Sim	Sim
K ₂ O (%)	Sim	Sim
Resistência com 1 dia (MPa)	Sim	Não

3.1.2.3 MONTAGEM DOS BANCOS DE DADOS TIPO B

Os Bancos de Dados do tipo B foram elaborados para ser utilizados por algoritmos que preveem a resistência à compressão aos 28 dias do cimento pozolânico utilizando entre seus *inputs* os teores de compostos principais do cimento Portland. Isso para se avaliar a viabilidade desse novo tipo de análise e sua acurácia e desempenho em relação à análise com teores de óxidos como *inputs*.

Os teores de compostos principais do cimento Portland não se encontram entre os parâmetros presentes na BDG que foi montada. Desse modo foi necessário que se realizasse a conversão dos teores de óxidos (obtidos por ensaios de FRX) em teores de compostos principais utilizando as adaptações das fórmulas de Bogue desenvolvidas por Gobbo (2009). Contudo, a fim de poder realizar esse tipo de conversão foi necessário que primeiramente efetuada uma adequação dos teores de compostos.

O processo de adequação consiste na separação da composição de óxidos do CPIV em composição de óxidos de cimento puro e composição de óxidos de argila calcinada, uma vez que as adaptações de Gobbo são aplicáveis teoricamente apenas nos teores de óxidos do cimento puro. Para a realização desse processo é necessário possuir as composições, em termos de óxidos, do CPIV e da argila calcinada, assim como o teor de argila calcinada (Teor de AC) presente no CPIV, conforme a Equação 3.1:

$$\text{Composição Cimento Puro} = (\text{Composição CPIV}) - (\text{Teor de AC}) \times (\text{Composição de AC}) \quad (3.1)$$

A equação acima então foi utilizada para se definir cada um dos teores de óxidos do cimento puro relevantes para o cálculo de seus compostos principais. Ou seja, para se saber o teor de SiO₂ do cimento puro se subtraiu do teor desse óxido presente no CPIV o teor de SiO₂ presente na argila calcinada presente na amostra multiplicado pelo teor desse material presente no CPIV, e o mesmo procedimento foi repetido para cada um dos demais óxidos em todo o campo amostral. Foi definido uma composição padrão da argila calcinada a fim de se poder utilizar a Equação 3.1. Esse teor foi calculado a partir de médias de composições de argilas calcinadas utilizadas pela cimenteira. A fim de manter os dados de produção sob sigilo, a composição padrão não será totalmente apresentada nos resultados.

Todos os conjuntos de dados passaram por esse processo de adequação e em seguida passaram pelas conversões de Bogue. As adaptações das fórmulas de Bogue adotadas neste trabalho são apresentadas abaixo:

$$C_3S = (4,07 \times (\text{CaO} - \text{CaO}_{\text{livre}})) - (7,6 \times \text{SiO}_2) - (6,72 \times \text{Al}_2\text{O}_3) - (1,43 \times \text{Fe}_2\text{O}_3) - (2,85 \times \text{SO}_3) \quad (3.2)$$

$$C_2S = (2,87 \times \text{SiO}_2) - (0,754 \times C_3S) \quad (3.3)$$

$$C_3A = (2,65 \times \text{Al}_2\text{O}_3) - (1,69 \times \text{Fe}_2\text{O}_3) \quad (3.4)$$

$$C_4AF = 3,04 \times \text{Fe}_2\text{O}_3 \quad (3.5)$$

A Equação 3.2 é uma das adaptações realizadas por Gobbo (2009) para estimação dos compostos principais a partir dos teores de óxidos do cimento. Essa equação foi adotada por levar em consideração o teor de gesso acrescido ao cimento (SO₃) e o teor de CaO livre presente na mistura, embora esse último teor não seja devidamente controlado pela cimenteira. As demais equações (3.3, 3.4 e 3.5) foram adotadas também conforme o recomendado por Gobbo (2009) e por Chaves (2021) em sua pesquisa que obteve sucesso em prever propriedades do CPI a partir de teores de óxidos.

A partir dos dados convertidos do BDG foram feitas novas compatibilizações do banco de dados geral para remover conjuntos de dados que apresentaram resultados inconsistentes. Esses casos ocorreram devido à prováveis erros de ensaio ou às próprias incertezas intrínsecas ao processo de conversão dos dados. As possíveis causas dessas inconsistências e as suas consequências são detalhadas no Capítulo 4 deste trabalho.

Após a remoção dos dados inconsistentes foram gerados três Bancos de Dados do tipo B. Um utilizando o parâmetro “resistência à compressão com 1 dia” como *input*, o Banco de Dados B1; outro utilizando o parâmetro “resistência à compressão com 7 dias” entre seus *inputs*, o Banco de Dados B2; e um terceiro sem utilizar nenhum parâmetro de resistência à compressão como *input*, o Banco de Dados B3, conforme pode ser observado na Tabela 3.2.

Tabela 3.2 - Inputs dos bancos de dados tipo B

Input	Base B1	Base B2	Base B3
C ₃ S (%)	Sim	Sim	Sim
C ₂ S (%)	Sim	Sim	Sim
C ₃ A (%)	Sim	Sim	Sim
C ₄ AF (%)	Sim	Sim	Sim
Resistência à Compressão a 1 dia (MPa)	Sim	Não	Não
Resistência à Compressão aos 7 dias (MPa)	Não	Sim	Não
Finura Blaine (cm ² /g)	Sim	Sim	Sim
Teor de Pozzolana (%)	Sim	Sim	Sim

Dessa maneira, ao fim de todos os processos, a Base de Dados Geral (BDG) originou 5 Bancos de Dados diferentes. Cada um desses bancos foi utilizado para treinar um algoritmo diferente a fim de que seus desempenhos fossem comparados. Abaixo são resumidos cada um desses bancos de dados:

- Banco de Dados A1: Adota teores de óxidos como *inputs* e utiliza a resistência à compressão com 1 dia como um *input*;
- Banco de Dados A2: Adota teores de óxidos como *inputs* e não utiliza nenhum valor de resistência à compressão como *input*;
- Banco de Dados B1: Utiliza como *input* teores de compostos principais do cimento, adota a resistência à compressão com 1 dia como *input*;
- Banco de Dados B2: Utiliza como *input* teores de compostos principais do cimento, além disso adota a resistência à compressão com 7 dias como *input* (e não a de 1 dia como no caso de B1);
- Banco de Dados B3: Utiliza como *inputs* teores de compostos principais do cimento, porém ao contrário dos outros bancos do tipo B, não adota nenhum valor de resistência à compressão como *input*.

3.2 ETAPA 02 – TREINAMENTO E TESTE DOS ALGORITMOS

A segunda etapa consiste no treinamento supervisionado e teste de cada um dos algoritmos elaborados. Os desempenhos de cada algoritmo de cada classe (A e B) são comparados e foi avaliado qual dos algoritmos de cada classe foi capaz de realizar previsões de maior qualidade.

Todos os algoritmos foram implementados na linguagem Matlab, uma vez que esta pode executar comandos específicos para técnicas de ML. Além disso, todos utilizaram técnicas de *Artificial Neural Networks* para realizar previsões devido ao seu já comprovado potencial de realizar previsões de propriedades de materiais cimentícios como o concreto e argamassas (ASTERIS et al. (2021); BEN CHAABENE et al. (2020), GAYATHRI et al. (2022)).

Mais especificamente foi adotada a técnica de *Multilayer Perceptron Artificial Neural Network* com duas camadas. Esse tipo de algoritmo funciona como uma rede neural onde cada neurônio de uma determinada camada está conectado com todos os neurônios da camada seguinte. A opção por essa classe de ANN com apenas 2 níveis foi tomada devido ao fato de que esse número de camadas é capaz de resolver problemas de grande complexidade com alta taxa de convergência mesmo com quantidades de dados muito menores do que seria necessário para algoritmos de apenas uma camada (GÉRON, 2019). No caso dos algoritmos do tipo A, foram utilizadas duas camadas com 200 neurônios cada, enquanto para os do tipo B foram utilizadas camadas de 150 neurônios.

A Tabela 3.3 apresenta os hiperparâmetros adotados para cada um dos algoritmos elaborados nesse trabalho. Vale ressaltar ainda que a elaboração dos algoritmos (programação, definição de hiperparâmetros e afins) não é objeto do escopo desse trabalho, o modelo do algoritmo já foi desenvolvido anteriormente pelo grupo de pesquisa NEXUM no PECC. Já em relação à nomenclatura, os algoritmos foram nomeados de acordo com seus respectivos bancos de dados, ou seja, o algoritmo treinado no Banco de Dados A1 foi nomeado Algoritmo A1, e o mesmo ocorreu de forma análoga para todos os demais algoritmos/modelos e bancos de dados.

Tabela 3.3 - Hiperparâmetros adotados para os algoritmos

Hiperparâmetros	Algoritmos				
	A1	A2	B1	B2	B3
Solver	Adam	Adam	Adam	Adam	Adam
Alpha	0,01	0,01	0,1	0,1	0,1
Nº de Neurônios	(200, 200)	(200, 200)	(150, 150)	(150, 150)	(150, 150)
Função Ativação	ReLU	ReLU	ReLU	ReLU	ReLU
Taxa de Aprendizado	0,001	0,001	0,01	0,01	0,01

3.2.1 TREINAMENTO E TESTE DOS ALGORITMOS

Os dados produzidos durante a Etapa 1 da Metodologia foram utilizados nessa etapa para treinar e testar cada algoritmo de *Machine Learning*. Cada Banco de Dados foi dividido em duas partes, a primeira com 80% dos dados para Treinamento, o Conjunto de Treinamento, e a segunda com os 20% restantes para Teste, o Conjunto de Teste. Tal proporção na divisão dos dados foi recomendada por Géron (2019) para previsões de ANN como as realizadas neste estudo.

3.2.1.1 TREINAMENTO DOS ALGORITMOS

Na fase de Treinamento Supervisionado cada algoritmo tem acesso apenas ao Conjunto de Treinamento. Dessa forma o algoritmo tem acesso tanto aos *inputs* e *outputs* presentes nesse conjunto e é treinado (e ensinado) de forma a correlacionar esses valores de maneira que possa prever valores a partir dos *inputs* que coincidam com os respectivos valores de *output* disponíveis no conjunto de treinamento. Ou seja, no caso dos algoritmos em questão, prever a resistência à compressão aos 28 dias a partir dos *inputs* adotados por cada algoritmo.

3.2.1.2 TESTE DE VALIDAÇÃO DOS ALGORITMOS

Após o treinamento do algoritmo, este está pronto para o processo de validação de seu treinamento, ou seja, a etapa de checagem de aprendizado, a etapa de Teste de Validação. Nessa fase o algoritmo tem acesso apenas aos valores de *input* do Conjunto de Teste (segunda parte de cada Banco de Dados), devendo prever valores de *outputs* de acordo com o que aprendeu na fase de Treinamento. É a partir dos resultados obtidos nessa etapa que foi possível avaliar o desempenho e capacidade de previsão de cada algoritmo analisado, ao se comparar os valores previstos por ele e os valores esperados de *outputs* (aos quais o algoritmo não teve acesso).

3.2.1.3 AVALIAÇÃO DOS RESULTADOS

A fim de se realizar a análise individual dos algoritmos treinados e testados nos diferentes bancos de dados, foi efetuada a análise de seus desempenhos a saber: R^2 , RMSE E MAPE. A seguir são detalhados esses parâmetros:

- RMSE (Root of Mean Square Error, ou Raiz do Erro Quadrático Médio), que se relaciona com o volume acumulado de erro em relação ao valor esperado para cada amostra analisada, quanto maior esse parâmetro, menor o desempenho do modelo em questão;
- R^2 (ou coeficiente de determinação), relacionado ao ajuste de um modelo a um conjunto de valores já existente, podendo variar entre 0 e 1, sendo 1 a indicação de um ajuste perfeito e quanto mais próximo o valor de R^2 desse valor melhor o modelo;
- MAPE (Mean Absolute Percentage Error, ou Erro percentual absoluto médio), é a média dos valores absolutos dos erros relativos, indicando o quão “espalhados” em relação aos valores esperados estão as estimativas de um modelo. Quanto menor for o valor desse estimador maior a precisão do modelo analisado. Seu cálculo se dá conforme a Equação 3.6 onde A_t indica o valor esperado para uma amostra, F_t o valor previsto para essa amostra e n a quantidade de amostras analisadas.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t} \quad (3.6)$$

Vale ressaltar que o parâmetro MAPE foi adotado apenas para a análise dos resultados de Teste de Validação. Isso pois é essa etapa que realmente demonstrará o potencial de aplicação do modelo analisado.

3.2.2 COMPARAÇÃO DE DESEMPENHO

Após as análises individuais, os modelos gerados foram comparados entre suas próprias classes (modelos do tipo A entre si, e modelos tipo B entre si) e seus desempenhos discutidos a partir de seus parâmetros de qualidade. A partir dessas análises foi definido qual modelo tipo A e tipo B teve o melhor desempenho entre os demais, ou seja, o modelo com melhor

desempenho para previsão utilizando teores de óxidos e o melhor algoritmo para realizar previsões utilizando teores de compostos principais. Isso de forma que estes possam ser comparados na etapa seguinte desse trabalho.

3.3 ETAPA 03 – COMPARAÇÃO DE RESULTADOS ENTRE MODELOS “A” E “B”

Nesta etapa, os dois algoritmos com melhor desempenho de cada classe (A e B) foram comparados. Essa comparação se deu por meio de seus parâmetros de qualidade e respectivos bancos de dados. As implicações teóricas por trás do comportamento dos algoritmos foram analisadas e o comportamento físico-químico de cada variável é levado em consideração para se comparar o desempenho de cada um dos modelos selecionados.

O desempenho de cada algoritmo foi comparado e foram feitas ponderações acerca de possíveis fatores que podem influenciar o desempenho dos modelos e aprimorar futuras previsões.

4 RESULTADOS

Neste capítulo serão apresentados os resultados obtidos a partir dos procedimentos descritos e executados no capítulo de metodologia. São apresentados os detalhamentos da BDG e de cada banco de dados montado, assim como os resultados da análise preliminar dos parâmetros fornecidos. Cada um dos modelos estudados tem seus resultados de previsão nas etapas de treinamento e teste apresentados, seus parâmetros de qualidade e resíduos de erro são analisados e por fim os algoritmos são comparados, a fim de avaliar seus desempenhos individuais e qual desses se mostrou mais eficiente na previsão da resistência à compressão aos 28 dias do CPIV.

4.1 ETAPA 01 – TRATAMENTO DOS DADOS E MONTAGEM DOS BANCOS DE DADOS

Nessa etapa estão apresentados os resultados do tratamento de dados constantes na BDG e a formação dos 5 Bancos de Dados utilizados para treinar os algoritmos.

4.1.1 TRATAMENTO DOS DADOS FORNECIDOS

Conforme descrito no Capítulo 3 – Metodologia, foi montada uma Base de Dados Geral (BDG) com 309 conjuntos de dados englobando diversos parâmetros controlados pela cimenteira analisada. Tal base de dados se encontra disponível no Apêndice I desse trabalho, e as suas primeiras linhas são apresentadas na Tabela 4.1 a seguir (dados de resíduo insolúvel e teor de pozolanas ocultos devido à sigilo de fabrica).

Tabela 4.1 - Exemplos de Conjuntos da BDG

Parâmetros	Conjunto 1	Conjunto 2	Conjunto 3	Conjunto 4
Resistência à Compressão 1 dia (MPa)	17,27	16,25	17,6475	17,46
Resistência à Compressão 3 dias (MPa)	28,80	28,38	28,64	29,53
Resistência à Compressão 7 dias (MPa)	36,54	38,20	37,78	38,08
Resistência à Compressão 28 dias (MPa)	45,25	42,22	40,95	43,71
Água de Consistência Normal (%)	34,20	34,20	34,2	34,20
Tempo de Início de Pega (min)	140	135	135	140
Tempo de Fim de Pega (min)	215	210	210	215
Granulometria na Peneira #200 (%)	1,60	2,29	2,74	2,56
Finura Blaine (cm ³ /g)	5485,00	5265,00	5084	5085,00
Perda ao Fogo (%)	2,72	2,59	2,27	2,27
Resíduo Insolúvel (%)	*	*	*	*
Teor de Pozolana (%)	*	*	*	*

CaO (%)	43,98	42,68	44,72	44,26
SiO ₂ (%)	31,07	31,87	30,83	31,04
Al ₂ O ₃ (%)	9,07	9,52	9,02	9,21
Fe ₂ O ₃ (%)	2,58	2,56	2,65	2,65
MgO (%)	4,38	4,22	4,29	4,28
SO ₃ (%)	3,91	3,70	3,77	3,85
Na ₂ O (%)	0,17	0,17	0,17	0,17
K ₂ O (%)	0,69	0,69	0,69	0,69

4.1.2 ANÁLISE DO BANCO DE DADOS GERAL E PARÂMETROS DISPONÍVEIS

A partir da BDG foi efetuada a montagem dos 5 diferentes bancos de dados. Inicialmente foi necessário que se realizasse uma análise preliminar dos parâmetros, das medidas centrais, de dispersão e da distribuição de cada variável e suas correlações na BDG.

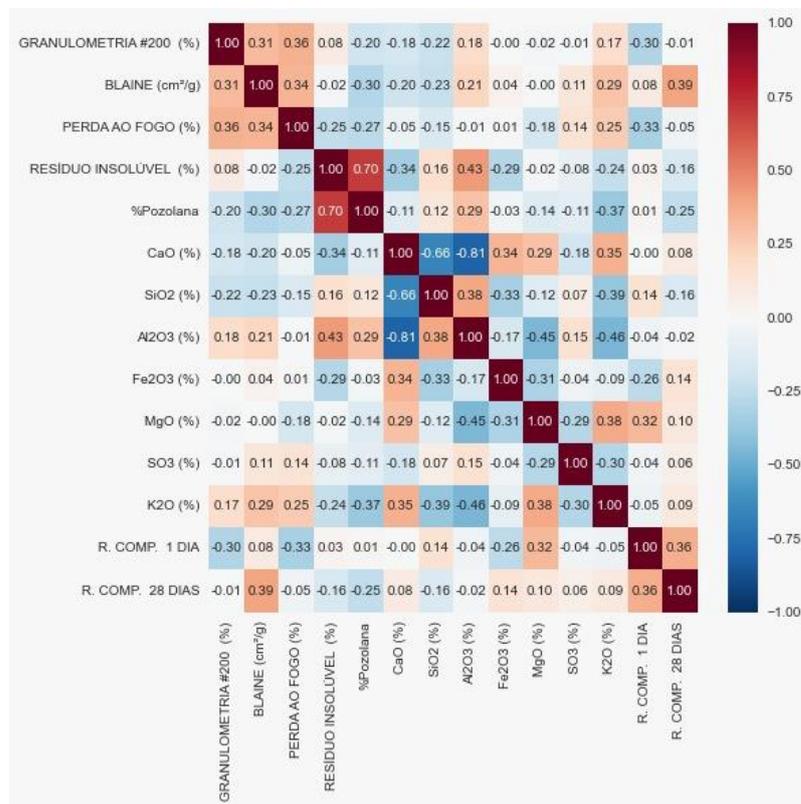


Figura 4.1 - Correlação das Variáveis da BDG

Foram efetuadas duas análises iniciais dos dados da BDG em relação às correlações entre as principais variáveis conforme apresentado na Figura 4.1. O esquema de cores dessa figura indica o nível de correlação entre as variáveis analisadas, quanto mais próximo do marrom maior a correlação direta e quanto mais escuro o tom de azul maior a correlação inversa.

Nota-se que a maior parte das variáveis apresenta valores de correlação considerados baixos, inferiores a 0,5. Em relação à resistência à compressão aos 28 dias nota-se que apenas os parâmetros de finura Blaine e Resistência a 1 dia apresentaram correlação maior que 0,36 (em termos absolutos). A correlação desses dois parâmetros se explica pela influência já comprovada entre finura de um material e sua dispersão em uma mistura, o que no caso do cimento resulta em maior hidratação, potencializando o ganho de resistência. Esse comportamento é mais relevante nas primeiras idades do cimento, o que justifica o baixo fator de correlação apresentado (DE LA VARGA, 2019; WANG et al., 2013). Já a resistência à compressão a 1 dia se correlaciona com a resistência aos 28 por ser um forte indicativo do potencial de hidratação do cimento analisado. Contudo, o cimento em questão é um cimento com uso de argila calcinada, que possui ganho de resistência mais acentuado a partir dos 7 dias (VASQUES, 2019; HUANG et al., 2022), o que atenua o indicativo de correlação dos dados e devido a isso não apresenta um valor tão relevante (acima de 0,5).

Ademais, foram encontradas correlações elevadas entre os parâmetros resíduo insolúvel e teor de argila calcinada. Essa correlação se dá devido ao fato de que o primeiro parâmetro advém do segundo, e inclusive pode ser calculado a partir do teor do MCS.

A baixa correlação entre os dados no geral foi atribuída ao rígido controle de produção do cimento Portland existente na indústria. Devido a esse controle há uma grande uniformidade nos dados presentes na BDG, com baixa variação, conforme apresentado na Tabela 4.2. Desse modo, como os parâmetros apresentam baixa variação em seus valores absolutos o processo de análise inicial não conseguiu identificar adequadamente correlações entre esses.

Uma vez que não se constataram correlações relevantes fora as da resistência a 1 dia e da finura Blaine, os demais parâmetros a serem adotados nos bancos de dados a serem montados foram selecionados segundo influências teóricas esperadas. Vale ressaltar que os dados referentes aos teores de resíduo insolúvel e teor de pozolana acrescentados não são apresentados a fim de se manter sob sigilo de produção os parâmetros adotados pela cimenteira.

Tabela 4.2 - Parâmetros da BDG

Parâmetro	Média	Desvio Padrão	Razão Desvio Padrão/Média
Resistência à Compressão a 1 dia (MPa)	13,337	1,861	0,140
Resistência à Compressão a 3 dias (MPa)	26,450	2,332	0,088
Resistência à Compressão aos 7 dias (MPa)	35,979	2,130	0,059
Resistência à Compressão aos 28 dias (MPa)	41,984	1,749	0,042
Água de Consistência Normal (%)	33,328	1,570	0,047
Tempo de Início de Pega (min)	130,83	21,88	0,17
Tempo de Fim de Pega (min)	219,42	16,99	0,08
Material passante na peneira #200 (%)	4,712	1,764	0,374
Finura Blaine (cm ² /g)	5921,233	552,267	0,093
Perda ao Fogo (%)	3,618	0,779	0,215
Resíduo Insolúvel (%)	**	**	**
Teor de Pozzolana (%)	**	**	**
CaO (%)	42,156	2,648	0,063
SiO ₂ (%)	29,685	1,632	0,055
Al ₂ O ₃ (%)	10,135	1,079	0,106
Fe ₂ O ₃ (%)	2,667	0,126	0,047
MgO (%)	4,300	0,211	0,049
SO ₃ (%)	3,807	0,235	0,062
Na ₂ O (%)	0,170	0,000	0,000
K ₂ O (%)	0,700	0,008	0,012

4.1.3 MONTAGEM DOS BANCOS DE DADOS TIPO A

Os bancos de dados tipo A foram construídos com o propósito de servir aos algoritmos que utilizam teores de óxidos como *inputs* para a previsão da resistência à compressão do cimento pozolânico. Dessa forma, a partir da análise preliminar efetuada nos parâmetros da BDG e da influência teórica que há entre certos parâmetros e a resistência à compressão, foram selecionados os *inputs* a serem utilizados para realizar a previsão nos algoritmos tipo A.

Como já explicitado durante o capítulo de Metodologia, foram montados dois bancos de dados tipo A, o Banco A1 e A2. A diferença entre estes se dá pelo fato de que o Banco A1 apresenta um *input* a mais que o Banco A2, a resistência à compressão com 1 dia do CPIV. A Tabela 4.3 apresenta dois dos conjuntos de dados do Banco de Dados A1, que foram utilizados para posterior alimentação do algoritmo A1 (que são idênticos aos do conjunto A2 com a exceção da exclusão do *input* resistência com 1 dia).

Tabela 4.3 - Exemplos de Conjuntos do Banco de Dados A1

Parâmetros	Conjunto 1	Conjunto 2
Material passante na peneira #200 (%)	4,310	2,570
Finura Blaine (cm ² /g)	6794	5629
Perda ao Fogo (%)	3,330	3,000
Resíduo Insolúvel (%)	*	*
Argila Calcinada (%)	*	*
CaO (%)	40,20	42,80
SiO ₂ (%)	29,19	31,31
Al ₂ O ₃ (%)	10,29	9,26
Fe ₂ O ₃ (%)	2,60	2,59
MgO (%)	4,32	4,32
SO ₃ (%)	3,85	3,94
K ₂ O (%)	0,71	0,70
Resistência com 1 dia (MPa)	14,923	12,315
Resistência com 28 dias (MPa)	44,068	40,438

Nota-se da Tabela 4.3 a presença dos teores de óxidos como maioria dos *inputs* selecionados para o algoritmo. Além desses, foram selecionados parâmetros relacionados à finura do cimento (que influencia na taxa de ganho de resistência com o tempo), como o finura Blaine e o material passante na peneira #200 (Finura na peneira 0,075 mm); o teor de argila calcinada que se relaciona diretamente com as reações pozolânicas no CPIV, uma vez que esse MCS é o responsável por esse fenômeno nesse material; os teores de perda ao fogo e resíduo insolúvel, que refletem uma camada a mais de detalhe acerca da composição química do cimento pozolânico; e finalmente a resistência à compressão com 1 dia, *input* que diferencia o banco A1 do A2 e um dos parâmetros que mais se relaciona com a resistência aos 28 dias em relação aos demais segundo a análise preliminar realizada.

Assim foram montados dois Bancos de Dados, A1 e A2, cada um com 309 conjuntos de dados advindos da BDG. O Banco A2 conta com conjuntos com 12 *inputs* e 1 *output* (resistência aos 28 dias), enquanto o Banco A1 possui 13 *inputs* e o mesmo *output*.

4.1.4 MONTAGEM DOS BANCOS DE DADOS TIPO B

Em seguida se iniciou o processo de montagem dos bancos de dados tipo B, que utilizam teores de compostos principais para a previsão da resistência do cimento pozolânico analisado. Para isso foi necessário inicialmente converter os teores de óxidos presentes na BDG em teores de compostos principais, uma vez que os compostos principais não estão entre os parâmetros disponibilizados na BDG.

4.1.4.1 CONVERSÃO DOS DADOS

Para a conversão dos dados por meio das fórmulas de Bogue é necessário inicialmente se adequar os teores de óxidos do cimento pozolânico em teores de óxidos do cimento comum (sem incorporação de argila calcinada). Dessa forma foi primeiramente realizado processo de adequação dos teores de óxidos presentes na BDG ao se subtrair do teor de cada um dos óxidos referentes à composição da argila calcinada incorporada no CPIV, conforme apresentado na Equação 3.1. É relevante ressaltar que essa composição é uma média das composições disponíveis, uma vez que não há um controle da composição amostra por amostra pela cimenteira. Toda a argila calcinada utilizada no CPIV vem da mesma jazida, embora dentro desta ainda exista variação na composição desse MCS. A composição da argila média não está disponível neste trabalho uma vez que esse dado é considerado segredo de produção pela cimenteira e não pode ser divulgado.

Os teores da composição média da argila foram aplicados na Equação 3.1 para adequação dos teores de óxidos do CPIV na BDG em teores de óxidos de cimento Portland comum. A Tabela 4.4 ilustra alguns desses casos.

Tabela 4.4 – Exemplos de adequação da Composição CPIV para Composição Cimento Portland Comum

Conjunto	Composição CPIV					Composição Cimento Portland Comum			
	CaO (%)	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)	Pozolana (%)	CaO (%)	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)
1	52,860	26,050	5,590	2,370	28,022	52,833	8,281	-2,815	1,655
2	43,270	31,500	9,900	2,540	29,733	43,242	12,646	0,981	1,782
3	43,030	31,850	10,030	2,560	29,000	43,002	13,461	1,331	1,821

É importante ressaltar que alguns dos conjuntos de dados gerados ao se aplicar o processo de transformação citado apresentaram valores incondizentes com a realidade (valores negativos de parte ou total dos óxidos), conforme ilustrado pelo conjunto 1 da Tabela 4.4. Esse comportamento se deu devido a variabilidade das argilas calcinadas utilizadas na composição do CPIV que variaram muito em relação à composição padrão, o que teve grande impacto durante o processo de adequação dos dados. Todos os casos com comportamento similar ao do conjunto 1 da Tabela 4.4 foram excluídos do processo e, portanto, não foram utilizados para a montagem dos bancos de dados tipo B.

Após a conclusão do processo de adequação, os conjuntos remanescentes da BDG adequados passaram pelo processo de conversão dos teores de óxidos em teores de compostos principais por meio das Fórmulas de Bogue (Equações 3.2 a 3.5). A Tabela 4.5 apresenta exemplos desse processo de conversão, onde em seu lado esquerdo se encontram os dados relativos à BDG que foram utilizados para se produzir os dados que formarão os Banco de Dados tipo B (ao lado direito da tabela).

Tabela 4.5 - Exemplos de conversão de dados para formação dos bancos de dados tipo B

Conjunto	Composição CPIV (BDG)					Composição Clínquer (Dados Convertidos)			
	CaO (%)	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)	Pozolana (%)	C ₃ S (%)	C ₂ S (%)	C ₃ A (%)	C ₄ AF (%)
1	43,03	31,85	10,03	2,56	**	50,174	0,748	0,254	5,540
2	44,07	29,00	9,35	2,64	**	47,817	2,920	1,751	6,149
3	42,41	29,34	10,51	2,68	**	45,771	1,499	3,054	6,103
4	40,91	29,73	10,77	2,66	**	39,988	5,646	3,220	5,985
5	42,49	31,56	10,87	2,64	**	29,935	19,044	3,724	5,948
6	43,98	31,07	9,07	2,58	**	55,941	-3,212	-1,161	5,713

Após essa conversão ainda foram apresentados resultados que não fazem sentido físico, com resultados negativos, como o conjunto 6 da Tabela 4.5, todos esses foram removidos do Banco de Dados B. Vale ressaltar que os resultados negativos se deram devido às incertezas das fórmulas de Bogue que foram desenvolvidas e adaptadas para cimentos puros, e não para um cimento pozolânico como o CPIV, assim como ao fato já citado das incertezas presentes na composição da argila calcinada utilizada em cada amostra.

Todo esse processo resultou na diminuição da quantidade de conjuntos da BDG aplicáveis para montagem dos Bancos de Dados tipo B. O espaço amostral passou de 309 conjuntos com óxidos da BDG para 81 conjuntos com teores de compostos principais para os bancos de dados tipo B.

4.1.4.2 MONTAGEM DOS BANCOS B1, B2 E B3

A partir dos conjuntos de dados convertidos foi iniciada a montagem dos bancos de dados com teores de compostos principais para utilização na previsão de resistência à compressão do cimento.

Foram montados três bancos de dados do tipo B, todos com 81 conjuntos de dados, com um único *output* (resistência à compressão aos 28 dias) porém com diferentes *inputs*. O primeiro banco a ser formado foi o Banco de Dados B1, utilizando os seguintes *inputs*:

Teores dos quatro compostos principais do cimento Portland (C_2S , C_3S , C_4AF e C_3A); teor de pozolana incorporada (devido à sua relação com os efeitos pozolânicos); finura Blaine (por se relacionar com a velocidade de hidratação, e conseqüente resistência ao longo do tempo do cimento hidratado); e o *input* “Resistência à compressão com 1 dia de idade”. O segundo banco, Banco de Dados B2, contou com as mesmas variáveis do Banco B1, contudo no lugar da “Resistência à compressão com 1 dia de idade” foi colocado o *input* “Resistência à compressão com 7 dias de idade” de modo que se torna possível avaliar a influência dessa variável ao se comparar os resultados dos algoritmos B1 com B2. Por fim o Banco de Dados B3 contou com os mesmos *inputs* do banco B1 com a retirada *input* “Resistência à compressão com 1 dia de idade”, de forma a analisar a influência desse fator no desempenho de previsões em relação aos algoritmos B1 e B2. A Tabela 4.6 apresenta exemplos de 2 dos conjuntos de dados de cada Banco tipo B.

Tabela 4.6 - Exemplos de Conjuntos do Banco de Dados Tipo B

Parâmetro	B1		B2		B3	
	Conjunto 1	Conjunto 2	Conjunto 1	Conjunto 2	Conjunto 1	Conjunto 2
C_3S (%)	34,27	39,53	34,27	39,53	34,27	39,53
C_2S (%)	14,90	6,79	14,90	6,79	14,90	6,79
C_3A (%)	1,68	1,09	1,68	1,09	1,68	1,09
C_4AF (%)	6,17	5,27	6,17	5,27	6,17	5,27
Resistência à Compressão aos 7 dias (MPa)	-	-	37,75	33,95	-	-
Resistência à Compressão a 1 dia (MPa)	13,30	13,34	-	-	-	-
Finura Blaine (cm^2/g)	6331,00	5403,00	6331,00	5403,00	6331,00	5403,00
Teor de Pozolana (%)	**	**	**	**	**	**
Resistência à Compressão aos 28 dias (MPa)	43,25	40,23	43,25	40,23	43,25	40,23

4.2 ETAPA 02 – TREINAMENTO E TESTE DOS ALGORITMOS

Esta seção apresentará os resultados do processo de treinamento e teste de validação de algoritmos para previsão da resistência à compressão aos 28 dias de cimentos do tipo CPIV. Será iniciada a análise pelo treinamento e teste dos algoritmos A1 e A2 e em seguida a comparação de seus desempenhos. Após isso serão apresentados os resultados dos mesmos processos para os algoritmos B1, B2 e B3. Destaca-se que serão efetuadas as análises de desempenho dentro de cada uma das classes a fim de se avaliar as melhores performances dos algoritmos do tipo A e do tipo B. Ressalta-se mais uma vez que todos os algoritmos foram

construídos utilizando a mesma técnica de ANN, diferindo apenas nos ajustes necessários para avaliar seus respectivos Bancos de Dados.

4.2.1 ALGORITMOS TIPO A

Nessa seção será tratado a respeito do treinamento, teste de validação e avaliação de desempenho dos algoritmos do tipo A. No caso desses dois algoritmos o procedimento de treinamento e teste foi o mesmo consistindo na separação de cada banco de dados em dois subgrupos, o de Treinamento e o de Teste de Validação. Os de Treinamento contendo 247 conjuntos de dados foram utilizados para treinar seus respectivos algoritmos do tipo A, de forma que esses tivessem acesso tanto aos *inputs* quanto *outputs* de cada conjunto de dados para poder se desenvolver e calibrar suas previsões. Já os subgrupos de Teste de Validação são compostos pelos demais 63 conjuntos de dados, e foram utilizados para avaliar a capacidade de previsão dos Modelos tipo A, isso porque durante a etapa de Teste o algoritmo teve acesso apenas aos *inputs* de cada um dos conjuntos de dados.

4.2.1.1 ALGORITMO A1

O treinamento do algoritmo A1 no Banco de Dados A1 se deu conforme explicitado no Capítulo 3. O resultado de seu treinamento é explicitado na Figura 4.2 abaixo, onde o valor da abscissas (eixo X) representa o valor real de resistência aos 28 dias e o valor das ordenadas (eixo Y) representa o valor previsto pelo algoritmo, de tal modo que os pontos que seriam originados de uma previsão perfeita formam a linha preta que cruza o gráfico. Desse modo, quanto mais distante um ponto se encontra no eixo Y da linha preta, maior o erro na previsão realizada. Já as linhas pontilhadas apontam os limites de erro relativo de 2,5% e 5,0% abaixo e acima dos valores de igualdade.

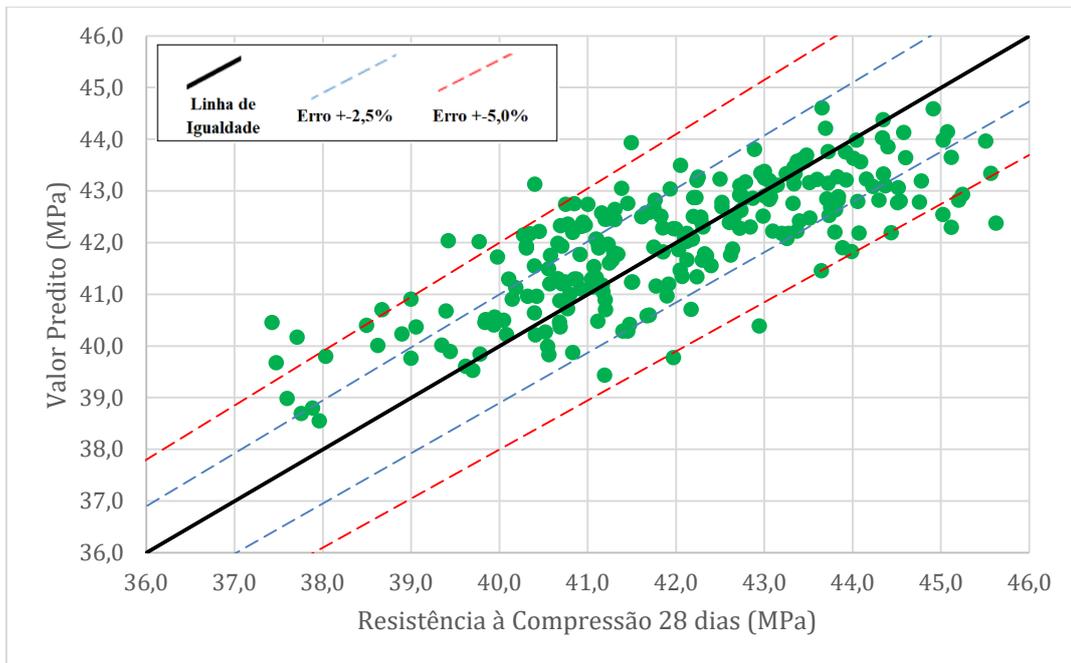


Figura 4.2- Resultados do Treinamento do Algoritmo A1

Dessa forma, ao se analisar a Figura 4.2 fica claro que há visível diferença entre os valores reais e valores previstos para a maioria dos pontos. Esse fato condiz com o valor de R^2 de 0,58 apresentado nesse processo e corrobora com valor obtido de RMSE de 1,135 MPa para o treinamento de algoritmo. Além disso, é possível perceber que a maior parte dos dados se manteve dentro do intervalo de erro relativo de 5%, indicando a concentração dos dados próximos à linha de previsão ideal.

O valor apresentado de R^2 é relativamente baixo ao ser comparado com valores encontrados em demais pesquisas envolvendo a previsão de resistência à compressão por meio de ML como observado na Tabela 2.3. Autores como Asteris et al. (2021) e Gayathri et al. (2022) utilizaram técnicas de RF e AdaBoost para prever a resistência de cimento Portland com valores de R^2 variando entre 0,84 a 0,99 para estes modelos, entretanto outros autores (SEVIM et al. (2021), HUANG et al. (2022), LI et al. (2022)) obtiveram valores de R^2 sempre acima de 0,70 durante o treinamento.

Contudo, no treinamento de algoritmo para previsões utilizando modelo de SVM de Asteris et al. (2021) o valor de R^2 obtido foi de 0,378, valor inferior ao obtido para o Modelo A1. Uma situação similar ocorre com o R^2 de treinamento de um algoritmo de regressão linear (RL) de Gayathri et al. (2022), cujo valor é de 0,46.

O valor de RMSE apresentado pelo Algoritmo A1 (1,135 MPa) difere do apresentado em outras pesquisas, por ser consideravelmente menor do que se encontra em outras literaturas. Esse comportamento indica que os erros absolutos apresentados durante esse treinamento foram inferiores aos valores absolutos das demais pesquisas, o que é um indicador de possível melhor desempenho. Os algoritmos de Gayathri et al. (2022) para previsão da resistência de cimentos Portland apresentaram RMSE variando entre 15,968 MPa e 5,103 MPa no treinamento, valores muito superiores aos do Modelo A1. Já Sevim et al. (2022) realizou previsões de resistência à compressão de cimentos pozolânicos utilizando ANN e obteve RMSE de 5,85 MPa na etapa de treinamento. Demais estudos como os de Huang et al. (2022), Li et al. (2022) e Asteris et al. (2021) apresentaram RMSE sempre acima de 1,305 MPa, dessa forma fica aparente que o algoritmo A1 apresenta um desempenho geral para este parâmetro superior aos demais trabalhos registrados, embora com R^2 inferior.

Já em relação ao Teste de Validação do algoritmo A1, os resultados são apresentados na Figura 4.3. Além disso, um resumo dos parâmetros de qualidade para o teste do algoritmo A1 se encontra na Tabela 4.7.

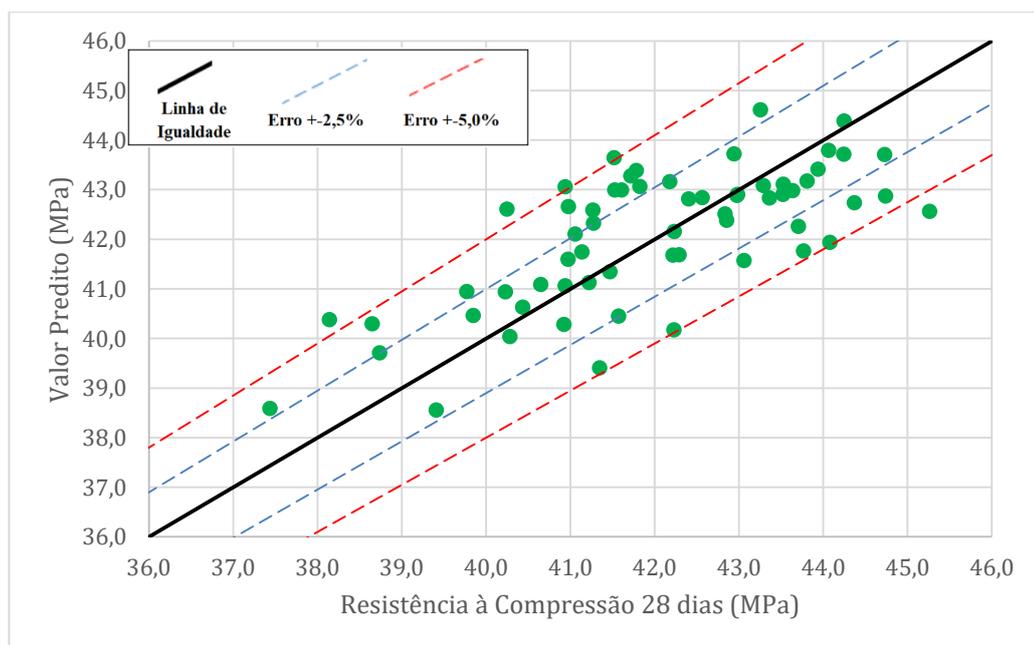


Figura 4.3 - Resultados do Teste de algoritmo A1

Assim como o que ocorreu para a fase de treinamento, o valor apresentado de R^2 na fase de validação (0,50) é inferior aos apresentados em demais pesquisas envolvendo a previsão de resistência à compressão por meio de ML. Os algoritmos de Sevim et al. (2021) de ANN e ANFIS para prever a resistência de cimentos Portland pozolânicos obtiveram

valores de R^2 de 0,894 e 0,946 respectivamente, na fase de validação, demonstrando desempenho fortemente superior ao do Algoritmo A1 na etapa de validação. Assim como todos os algoritmos desenvolvidos por Gayathri et al. (2022) apresentaram valores de R^2 superiores a 0,78 na etapa de validação. Já os algoritmos de ANN para previsão de resistência aos 28 dias de Shi e Dong (2011), Zhang et al. (2022), Huang et al. (2021) e Alkadhim et al. (2022) apresentaram R^2 sempre superiores a 0,65. Vale ressaltar entretanto que todos esses trabalhos utilizaram uma quantidade de *inputs* consideravelmente inferior (chegando a valores como 3 ou 4 parâmetros) o que induz os algoritmos a obter valores de R^2 superiores ao deixar seu funcionamento mais próximo de uma função linear quando comparados com o modelo de A1 que utiliza 13 *inputs* diferentes. Esse maior número de *inputs* acaba por tornar o processamento mais complexo para o algoritmo A1 e por consequência chega a afetar o valor de R^2 .

Outros trabalhos similares como os de Marani et al. (2020), Shanmugasundaram et al. (2022), Kumar et al. (2020) e Adel et al. (2022) também apresentaram valores de R^2 na etapa de validação superiores a 0,681 para diferentes tipos de modelos de ML. Entretanto, esses apresentaram quantidades de *inputs* mais próximas às adotadas nesse trabalho (entre 10 e 13 parâmetros), o que indica que seu ajuste foi realmente superior ao de A1 (com R^2 superior e quantidade de entradas similares).

Vale ainda ressaltar que trabalhos como os de Shi e Dong (2011), Alkadhim et al. (2022) e Turk et al. (2023) utilizaram bancos de dados com quantidade de conjuntos consideravelmente inferiores aos adotados nessa pesquisa. Dessa forma esses algoritmos foram treinados em campos amostrais mais limitados numericamente e por consequência colaboraram para um fator R^2 mais elevado quando comparado com o algoritmo A1.

Tabela 4.7 - Parâmetros do Algoritmo A1 Testado

R^2 de Teste	0,50
RMSE de Teste [MPa]	1,204
Erro Absoluto	
Média [MPa]	0,999
Erro Relativo	
MAPE	2,36%
Desvio Padrão	1,65%
Máximo	5,97%
Mínimo	0,18%

O valor de R^2 na etapa de validação indica que o modelo não foi capaz de interpretar a completude dos fatores que influenciam no valor de resistência à compressão aos 28 dias de idade do cimento. Ou seja, a partir dessa análise isolada pode-se concluir que os *inputs* adotados não foram suficientes para traduzir com exatidão o comportamento de desenvolvimento de resistência do cimento CPIV. Outros fatores serão analisados para se avaliar o comportamento completo do algoritmo e sua real aplicabilidade.

Ao abordar o valor de RMSE obtido (1,204 MPa), nota-se que este difere de outras pesquisas, por ser menor do que grande parte da literatura pesquisada, assim como ocorreu na etapa de treinamento. Logo, mais uma vez há uma indicação de melhor desempenho, em valores absolutos, do modelo desenvolvido em relação aos demais modelos da literatura. Valores de RMSE variando de 7,467 a 7,530 MPa foram obtidos por Huang et al. (2021) na previsão da resistência de cimentos Portland com uso de ANN com diferentes quantidades de camadas. Diversos outros trabalhos utilizando outras técnicas (DT, AdaBoost, XGBoost, RF, entre outras) apresentaram valores de RMSE superiores ao do Modelo A, como Gayathri et al. (2022), Alkadhim et al. (2022), Adel et al. (2022), entre outros como é possível observar na Tabela 2.3. Apenas os trabalhos de Shi e Dong (2011) e Ma et al. (2021) apresentaram valores de RMSE inferiores aos do algoritmo A1. Dessa forma, fica nítido que o valor encontrado desse parâmetro para o Modelo A1 na fase de validação demonstra desempenho superior aos demais artigos encontrados na literatura, de forma similar ao ocorrido na etapa de teste do algoritmo. Além disso, pode-se associar esse comportamento à baixa variabilidade dos dados fornecidos pela cimenteira.

Os valores de erro relativo da previsão se mantiveram inferiores a 6%, valor limite considerado para erro em relação à média durante ensaios de resistência à compressão segundo a NBR 7215 (ABNT, 2019). Tal fato se torna visível ao se analisar a Figura 4.3 onde a grande maioria dos pontos se concentra dentro do intervalo de 5% de erro relativo. Somado a esse fato, pode-se notar que o erro absoluto teve média inferior a 1 MPa, em um universo onde os *outputs* esperados variam em valores absolutos de 37 a 46 MPa. Constatou-se ainda um erro relativo máximo de 5,97%, e a maior parte dos dados com erro relativo inferior a 4%, girando em torno de 2,36% conforme indicado pela MAPE da distribuição e observado na Figura 4.4 que apresenta os resíduos de erro relativo do algoritmo A1. Tais dados apontam para uma eficiência do modelo em gerar resultados que apesar de não serem exatos

(conforme indicado pelo valor moderado de R^2), se mostram confiáveis dentro de uma margem de erro diminuta nos termos da engenharia civil (menor que 6%).

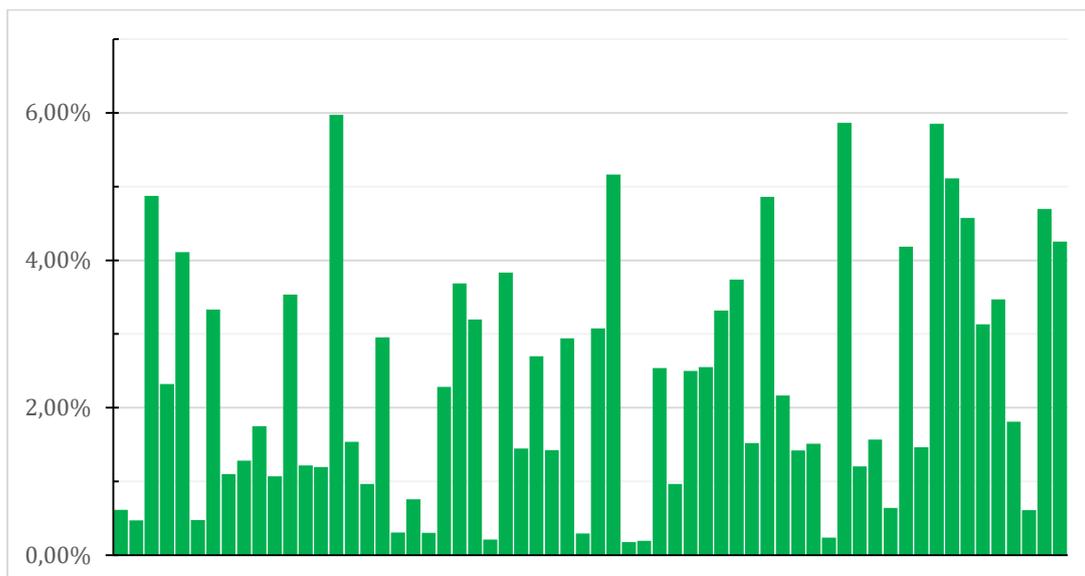


Figura 4.4 - Resíduos de erro relativo nas previsões do algoritmo A1

Todos esses fatores podem indicar a aplicabilidade desse modelo que utiliza os teores de óxidos para previsões de resistência à compressão do CPIV. Isso desde que seja levada em conta uma margem de erro relevante, que pode ser considerada aceitável a depender do propósito do uso do algoritmo.

4.2.1.2 ALGORITMO A2

Em seguida foi efetuado o treinamento do Algoritmo A2, utilizando o Banco de Dados A2, de forma análoga ao que ocorreu com o Algoritmo A1. Ao se analisar a Figura 4.5 é nítida a diferença entre os valores esperados e previstos para a maioria dos pontos. Pode-se notar uma maior dispersão dos dados em relação ao algoritmo A1, o que condiz com o valor de R^2 de 0,55 apresentado nesse processo e concorda com valor obtido de RMSE de 1,174 MPa para o treinamento desse algoritmo. Apesar disso, a maior parte dos dados se manteve dentro do intervalo de erro relativo de 5%, indicando a concentração dos dados próximos à linha de previsão ideal.

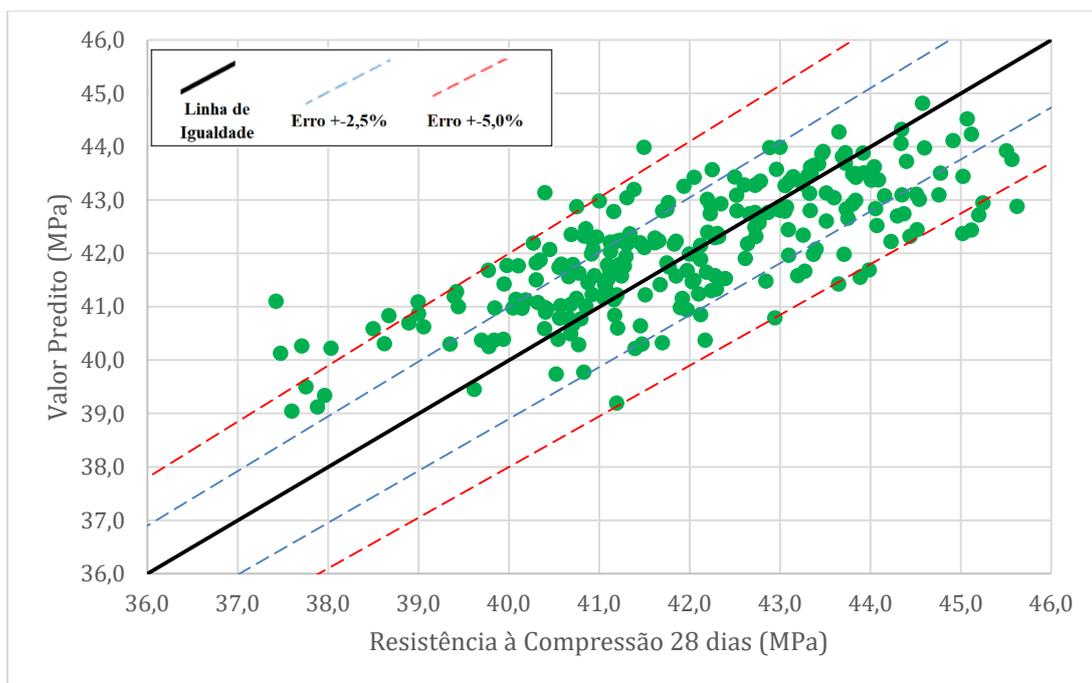


Figura 4.5 - Resultados do Treinamento do Algoritmo A2

O valor apresentado de R^2 é relativamente baixo ao ser comparado com valores encontrados em demais pesquisas envolvendo a previsão de resistência à compressão por meio de ML como observado na Tabela 2.3. Contudo, exceções ocorrem no treinamento de A2 assim como para o Algoritmo A1, como para as previsões de Asteris et al. (2021) e Gayathri et al. (2022) com valores de R^2 de 0,378 e 0,46 respectivamente.

O valor de RMSE apresentado pelo Algoritmo A2 (1,174 MPa) é relevantemente menor do que os apresentados em outras literaturas. Pesquisas como as de Huang et al. (2022), Li et al. (2022) e Asteris et al. (2021) apresentaram valores de RMSE sempre acima de 1,305 MPa, de forma que fica aparente que o algoritmo A2 apresenta um desempenho geral para este parâmetro nesse quesito superior aos demais trabalhos registrados, embora com R^2 inferior.

A Figura 4.6 apresenta os resultados da etapa de teste de validação do algoritmo A2. O valor apresentado de R^2 na fase de validação (0,34) é inferior aos apresentados em demais pesquisas envolvendo a previsão de resistência à compressão por meio de ML, assim como na fase de treinamento. Em relação à literatura detalhada na Tabela 2.3 apenas um dos algoritmos de Oey et al. (2019) (que conta com 20 *inputs*) apresentou valor de R^2 inferior ao apresentado pelo algoritmo A2. Trabalhos como os de Marani et al. (2020), Kumar et al. (2020), Shi e Dong (2011), Adel et al. (2022) e Alkadhim et al. (2022) também apresentaram

valores de R^2 na etapa de validação superiores a 0,681 para diferentes tipos de modelos de ML. Fica claro que houve uma grande dispersão de dados e um ajuste consideravelmente baixo para o modelo em questão.

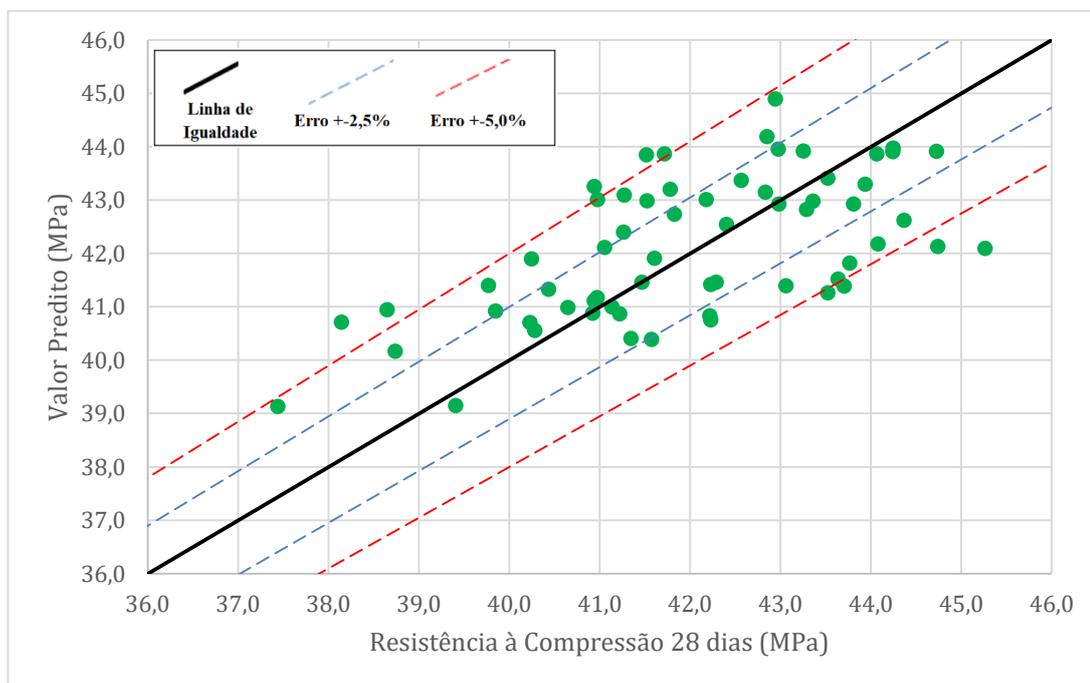


Figura 4.6 - Resultados do Teste do Algoritmo A2

O baixo valor de R^2 na etapa de validação indica que o modelo não foi capaz de interpretar a completude dos fatores que influenciam no valor de resistência à compressão aos 28 dias de idade do cimento. Dessa forma se considerou que os *inputs* adotados não foram suficientes para traduzir o comportamento de desenvolvimento de resistência do cimento CPIV. A Tabela 4.8 apresenta os demais parâmetros de qualidade referentes ao teste de validação do algoritmo A2.

Tabela 4.8 - Parâmetros do Algoritmo A2 Testado

R^2 de Teste	0,34
RMSE de Teste [MPa]	1,385
Erro Absoluto	
Média [MPa]	1,128
Erro Relativo	
MAPE	2,69%
Desvio Padrão	1,91%
Máximo	7,00%
Mínimo	0,02%

Ao abordar o valor de RMSE obtido (1,385 MPa), nota-se que este é consideravelmente pequeno em relação a outras pesquisas. Logo, mais uma vez há uma indicação de melhor desempenho, em valores absolutos, do modelo desenvolvido em relação aos demais modelos da literatura. Tal fato é similar ao que ocorreu com o Algoritmo A1, de forma que ambos os algoritmos (A1 e A2) apresentaram desempenhos superiores no quesito de RMSE aos de Huang et al. (2012), Gayathri et al. (2022), Adel et al. (2022) e Alkadhim et al. (2022).

Os valores de erro relativo da previsão foram superiores a 6%, valor limite considerado para erro em relação à média durante ensaios de resistência à compressão segundo a NBR 7215 (ABNT, 2019) (foi apresentado 7% por A2). Desse modo pode-se dizer que a taxa de erro relativo desse algoritmo é maior em média do que o erro permitido normativamente durante os ensaios experimentais, o que é um grande ponto negativo para esse modelo. Isso se dá porque esse fato indica que o erro do algoritmo pode ser mais incerto do que a escolha de um valor arbitrário a partir de estimativas do limite da norma.

Contudo, a MAPE apresentada teve valor de 2,69% o que se apresenta visualmente com grande parte dos valores girando em torno desse valor de erro relativo na Figura 4.6. Esses fatores podem indicar uma inadequação desse modelo que utiliza os teores de óxidos para previsões de resistência à compressão do CPIV. Isso considerando padrões normativos brasileiros e o uso comercial ou científico do cimento analisado.

4.2.1.3 COMPARAÇÃO DE DESEMPENHO

A Tabela 4.9 reinterpreta os parâmetros de qualidade das etapas de teste de validação dos algoritmos A1 e A2 para fins de comparação. Nota-se que o Algoritmo A1 apresentou desempenho superior em relação ao Algoritmo A2 em todos os parâmetros com exceção do erro relativo mínimo. Contudo, esse parâmetro isolado não é capaz de compensar todos os demais para o Algoritmo A2.

A partir dos resultados fica claro que a exclusão do *input* “resistência à compressão com 1 dia” afetou significativamente a capacidade do algoritmo em prever a resistência aos 28 dias do CPIV. Houve uma queda de cerca de 32% no encaixe da função proposta pelo algoritmo, ilustrada pela queda de R^2 de A1 de 0,50 para 0,34 em A2.

Tabela 4.9 – Comparação de Parâmetros dos Algoritmos Tipo A

Parâmetros	A1	A2
R ² de Teste	0,50	0,34
RMSE de Teste [MPa]	1,204	1,385
Erro Absoluto		
Média [MPa]	0,999	1,128
Erro Relativo		
MAPE	2,36%	2,69%
Desvio Padrão	1,65%	1,91%
Máximo	5,97%	7,00%
Mínimo	0,18%	0,02%

Já os valores de RMSE foram afetados com menor intensidade, mas ainda assim houve um aumento de 15% no valor desse parâmetro para A2 em relação ao primeiro algoritmo, o que indica clara queda de desempenho do segundo modelo. Ressalta-se, contudo, que ainda sim os valores encontrados para esse parâmetro se encontram consideravelmente baixos em relação à literatura já publicada para ambos os algoritmos, conforme já discutido em seções anteriores. Concomitantemente, o valor médio do erro absoluto do Algoritmo A2 subiu em relação ao A1, o que corrobora a importância do *input* removido para um melhor desempenho do modelo de previsão.

Como reflexo da queda do R² e aumento do RMSE e da média do erro absoluto, os parâmetros relacionados aos erros relativos também apresentaram queda em seus desempenhos para o algoritmo A2. Houve elevação de todos os parâmetros com exceção do valor mínimo, o que indica uma maior dispersão dos dados previstos, o que se reflete no valor de R² mais elevado.

Fica claro que a incorporação da resistência à compressão com 1 dia como *input* não resulta em grandes elevações no valor de R². Embora o não uso desse *input* seja consideravelmente prejudicial ao modelo para previsão da resistência aos 28 dias.

Dessa forma, levando todos os parâmetros de qualidade em consideração e as análises feitas, o Algoritmo A1 foi definido como o mais eficiente em realizar previsões de resistência à compressão aos 28 dias para o cimento pozolânico analisado. Isso devido à superioridade de seus parâmetros, que apresentaram menores erros relativos e absolutos e um melhor encaixe do Modelo aos dados de teste. Além disso, o modelo A2 não é capaz garantir que seus valores possuam erros relativos dentro do padrão permitido (e por consequência atingido

para produção de cimentos para fins comerciais) em ensaios experimentais da NBR 7215 (ABNT, 2019).

4.2.2 ALGORITMOS TIPO B

Essa seção tratará a respeito do treinamento, teste de validação e avaliação de desempenho dos algoritmos do tipo B. Esses três algoritmos foram submetidos aos mesmos procedimentos de treinamento e teste, consistindo na separação de cada banco de dados em dois subgrupos, o de Treinamento e o de Teste de Validação. Os de Treinamento contendo 64 conjuntos de dados foram utilizados para treinar seus respectivos algoritmos do tipo A, de forma que esses tivessem acesso tanto aos *inputs* quanto *outputs* de cada conjunto de dados para poder se desenvolver e calibrar suas previsões. Já os subgrupos de Teste de Validação são compostos pelos demais 17 conjuntos de dados, e foram utilizados para avaliar a capacidade de previsão dos Modelos tipo B, isso porque durante a etapa de Teste o algoritmo teve acesso apenas aos *inputs* de cada um dos conjuntos de dados.

4.2.2.1 ALGORITMO B1

O primeiro modelo, o Modelo B1, realiza previsões de resistência com 28 dias utilizando teores de compostos principais do cimento, teor de argila calcinada incorporada, finura Blaine e resistência com 1 dia de idade. Os resultados de seu treinamento são apresentados na Figura 4.7.

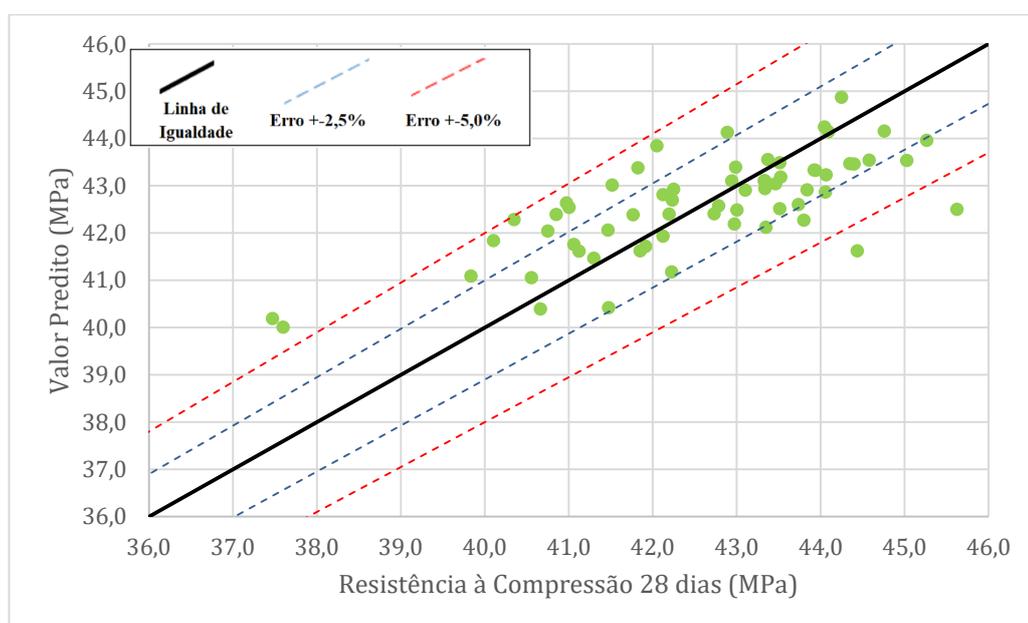


Figura 4.7 - Resultados do Treinamento do Algoritmo B1

Nota-se que grande parte dos resultados apresentou erro relativo de no máximo 5%, apesar de uma notável dispersão dos dados em relação à linha de igualdade. O valor de R^2 resultante desta distribuição é de 0,52, fator superior aos modelos do tipo A. Assim como mencionado anteriormente para os modelos tipo A, o valor de R^2 do Modelo B1 é consideravelmente inferior aos apresentados em demais pesquisas similares como as de Sevim et al. (2021), Huang et al. (2021), Asteris et al. (2021) e Li et al. (2022) conforme apresentado na Tabela 2.3, embora nessa mesma tabela seja possível observar alguns poucos algoritmos com R^2 de treinamento inferiores ao do algoritmo B1.

O valor de RMSE apresentado no treinamento do algoritmo B1 foi de 1,136 MPa, valor muito similar ao apresentado pelo algoritmo A1 em seu treinamento (que também utiliza o *input* “resistência com 1 dia” e possui RMSE de 1,135 MPa). Sabendo disso e analisando os dados constantes da Tabela 2.3 relativos ao treinamento dos dados, é possível observar que poucos algoritmos (como Abidin et al. (2022) e Adel et al. (2022)) apresentaram valor de RMSE inferiores ao do algoritmo B1, e por consequência desempenho superior nesse parâmetro. Assim pode-se dizer que, em relação à etapa de treinamento, o algoritmo B1 apresentou um dos melhores desempenhos para o parâmetro no universo de algoritmos analisados e revisados na literatura (segundo a Tabela 2.3).

Na Figura 4.8 e na Tabela 4.10 são apresentados os resultados da etapa de Teste do algoritmo B1 e seus parâmetros de qualidade. O parâmetro R^2 (0,40) se apresentou consideravelmente baixo, inferior aos resultados de outras pesquisas que também trabalham com previsão de resistência à compressão de cimento Portland, cujos valores de R^2 se apresentam majoritariamente sempre acima de 0,80 (ASTERIS et al. (2022), MARANI et al. (2020), HUANG et al. (2021), SHI e DONG (2011), ZHANG et al. (2022), GAYATHRI et al. (2022), SEVIN et al. (2021)). Importante também se atentar à quantidade de *inputs* e conjuntos de dados utilizados por cada um dos autores citados, todos esses com menor quantidade de *inputs* do que o algoritmo B1, o que induz os algoritmos a aproximar seu R^2 mais do valor 1,00 e consequentemente apresentar R^2 mais elevados do que o apresentado por B1. Vale ressaltar que ainda assim o valor de R^2 do Modelo B1 foi maior que o do algoritmo A2 em sua etapa de teste, o que é mais um fator que indica a importância do uso do *input* “Resistência à compressão com 1 dia” para previsões da resistência aos 28 dias.

Ademais, o valor de RMSE na etapa de teste (1,673 MPa) também se apresenta menor que grande parte dos estudos catalogados (Tabela 2.3) conforme ocorrido com os algoritmos

tipo A, inclusive para todos os algoritmos do tipo ANN com exceção dos desenvolvidos por Shi e Dong (2011), Ma et al. (2021) e Zhang et al. (2022).

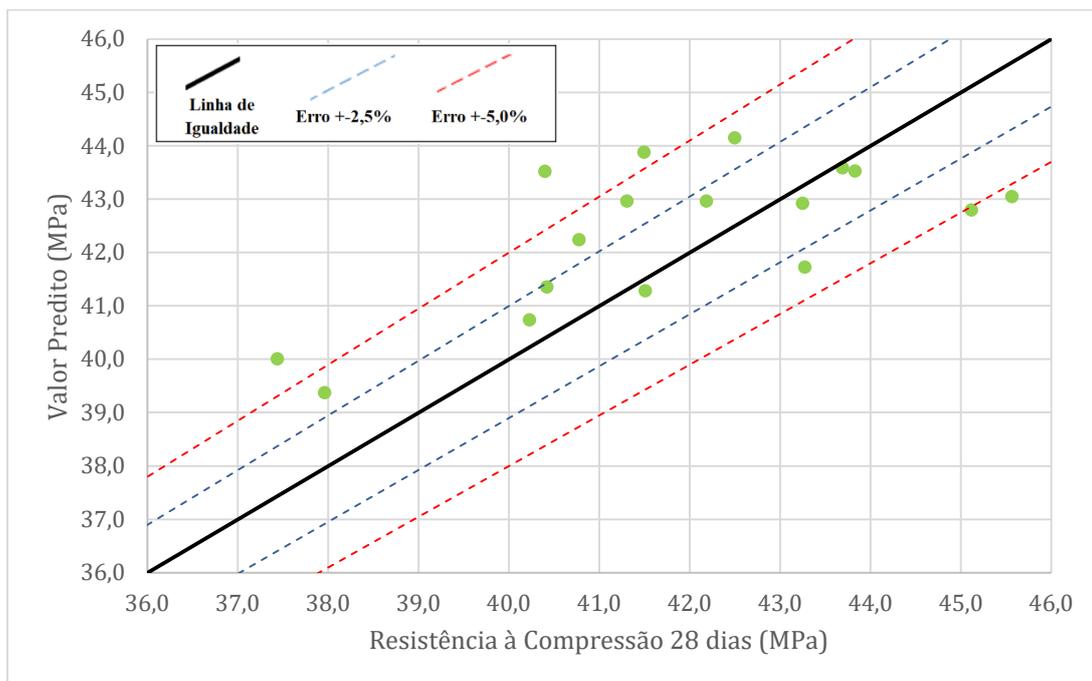


Figura 4.8 - Resultados de Teste do Algoritmo B1

Os dados apresentados na Tabela 4.10 indicam que foram detectados muitos erros de previsão, contudo todos com valores baixos (absolutos e relativos). Essa afirmação é confirmada ao analisar os demais parâmetros fornecidos pela Tabela 4.10 e pela Figura 4.8 onde pode-se ver que o ruído apresentado por esses erros é relativamente pequeno, contudo, muito notável, o que é resultado de uma baixa adaptação do algoritmo aos dados analisados (R^2 baixo).

Tabela 4.10 - Parâmetros do Algoritmo B1 Testado

R^2 de Teste	0,40
RMSE de Teste [MPa]	1,673
Erro Absoluto	
Média [MPa]	1,400
Erro Relativo	
MAPE	3,38%
Desvio Padrão	2,23%
Máximo	7,71%
Mínimo	0,25%

A Tabela 4.10 indica um erro absoluto médio de 1,40 MPa. Sabendo que os valores de *output* esperados variam entre 37 e 46 MPa, pode-se assumir que o erro absoluto médio varia

entre 3,78% e 3,04% do valor dos *outputs* esperados, valor consideravelmente baixo, que indica certa eficácia na previsão do algoritmo. Apoiando essa premissa, há os baixos valores de desvio padrão do erro relativo (de 2,23%) e MAPE de 3,38% indicando uma proximidade considerável entre os valores previstos e os valores esperados. Vale apontar ainda que a Tabela 4.10 ainda indica que o erro relativo máximo apresentado foi 7,71%, valor notadamente baixo quando comparado com os demais na Tabela 2.3, contudo elevado ao se comparar o limite de 6% estabelecido para ensaios experimentais pela NBR 7215 (ABNT, 2019), assim como ocorreu para o algoritmo A2.

Desse modo se conclui que as previsões feitas durante a fase de teste do modelo B1 não apresentarem os valores esperados, o que refletiu nos valores de erro relativo. Além disso, o valor de R^2 foi considerado baixo até para os padrões dos algoritmos tipo A, que já foram considerados baixos quando comparados com o restante da literatura analisada.

4.2.2.2 ALGORITMO B2

A partir do Banco de Dados B2, foi efetuado treinamento do algoritmo de ANN utilizando um subconjunto desses dados, o conjunto de treinamento. Ressalta-se que nesse caso foram utilizados com *inputs* os teores de compostos principais, resistência à compressão aos 7 dias, finura Blaine e teor de pozolana. A Figura 4.9 apresenta a correlação entre os valores esperados e previstos nesse processo treinamento.

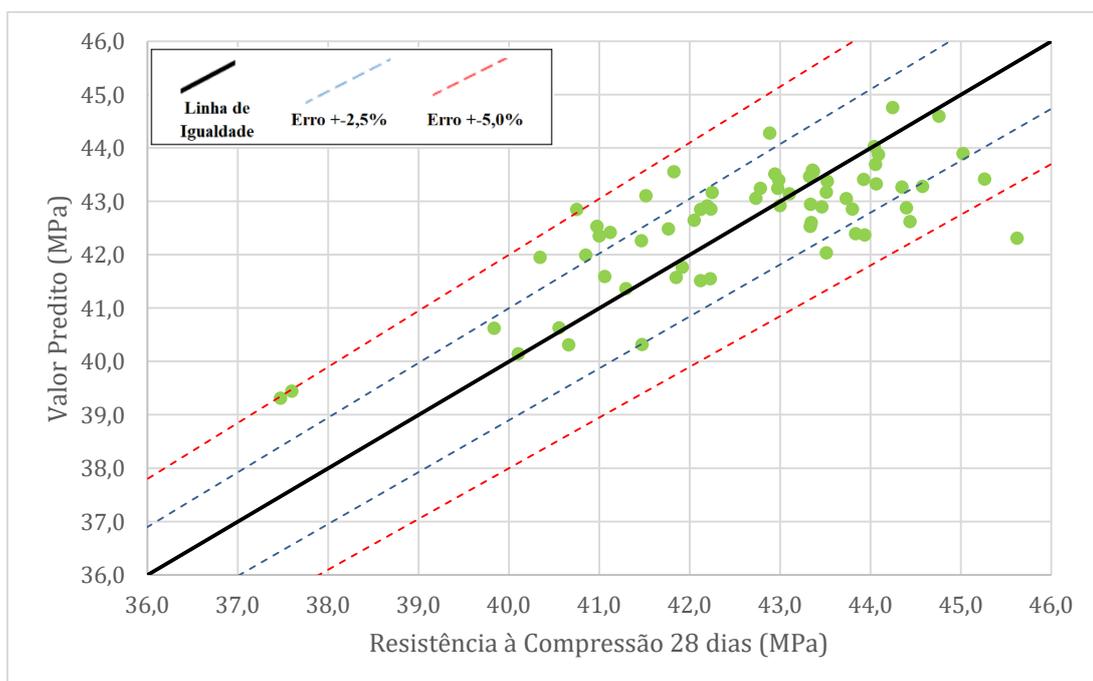


Figura 4.9 - Resultados do Treinamento do Algoritmo B2

Nota-se que apesar de uma notável dispersão dos dados em relação à linha de igualdade, praticamente todos os resultados apresentaram erro relativo de no máximo 5%. O valor de R^2 resultante desta distribuição é de 0,58, similar ao ocorrido com os modelos do tipo A e o modelo B1. Assim como mencionado anteriormente para os modelos desenvolvidos até essa etapa, o valor de R^2 do Modelo B2 é consideravelmente inferior aos apresentados em demais pesquisas similares (SEVIM et al. (2021), HUANG et al. (2022), ASTERIS et al. (2021), TURK et al. (2023)) como é possível se observar na Tabela 2.3. Além disso, os únicos algoritmos com valores de R^2 de treinamento inferiores aos do Algoritmo B2 são os de SVM de Asteris et al. (2021) e de RL de Gayathri et al. (2022).

Mais uma vez vale se ressaltar as diferenças entre as quantidades de *inputs* e tamanho de bancos de dados das referências da literatura e dos modelos desenvolvidos nesse trabalho. No caso dos algoritmos tipo B, cada conjunto de dados conta com 7 *inputs* (ou 6 no caso de B3), valor próximo à média dos demais artigos da literatura. Dessa forma a comparação em termos de quantidade de parâmetros de entrada e valor de R^2 dos algoritmos se torna mais justa do que o ocorreu com os algoritmos do tipo A (que contam com 12 parâmetros).

O valor de RMSE apresentado no treinamento do algoritmo B2 foi de 1,513 MPa, valor inferior à ambos os valores desse parâmetro (treinamento e teste) apresentados pelo algoritmo B1. Assim é possível inferir a partir desse parâmetro que o algoritmo B2 apresentou menores erros absolutos que o algoritmo B1 em seu treinamento. Sabendo disso e analisando os dados constantes da Tabela 2.3 relativos ao treinamento dos dados, é possível observar que apenas dois algoritmos apresentaram valor de RMSE inferior ao do algoritmo B2, e por consequência desempenho superior. Assim pode-se dizer que, em relação à etapa de treinamento, o algoritmo B2 apresentou um dos melhores desempenhos para o parâmetro no universo de algoritmos analisados.

Na Figura 4.10 e na Tabela 4.11 são apresentados os resultados da etapa de Teste do algoritmo B2 e seus parâmetros de qualidade. Assim como no Modelo B1, o parâmetro R^2 (0,51) se apresentou consideravelmente baixo, inferior aos resultados de outras pesquisas que também trabalham com previsão de resistência à compressão de cimento Portland, cujos valores de R^2 se apresentam majoritariamente acima de 0,80 (ASTERIS et al., 2022, MARANI et al., 2020; HUANG et al., 2021, SHI e DONG, 2011; ABIDIN et al., 2022, ADEL et al., 2022, LI et al., 2022, ZHANG et al., 2022, HUANG et al., 2022, GAYATHRI et al., 2022, SEVIN et al., 2021). Além disso, o valor de RMSE na etapa de teste (1,513 MPa)

também se apresenta menor que os demais estudos (ASTERIS et al., 2022; MARANI et al., 2020; HUANG et al., 2021; ABIDIN et al., 2022; ADEL et al., 2022; LI et al., 2022; ALKADHIM et al., 2022; HUANG et al., 2022; GAYATHRI et al., 2022; SEVIN et al., 2021; OEY et al., 2019) conforme ocorrido com os Modelos do tipo A, inclusive para todos os algoritmos do tipo ANN com exceção do desenvolvido por Shi e Dong (2011). Nota-se ainda que a maioria dos resultados se encontra dentro do intervalo de até 5% de erro relativo, não havendo erros relativos superiores a 8%.

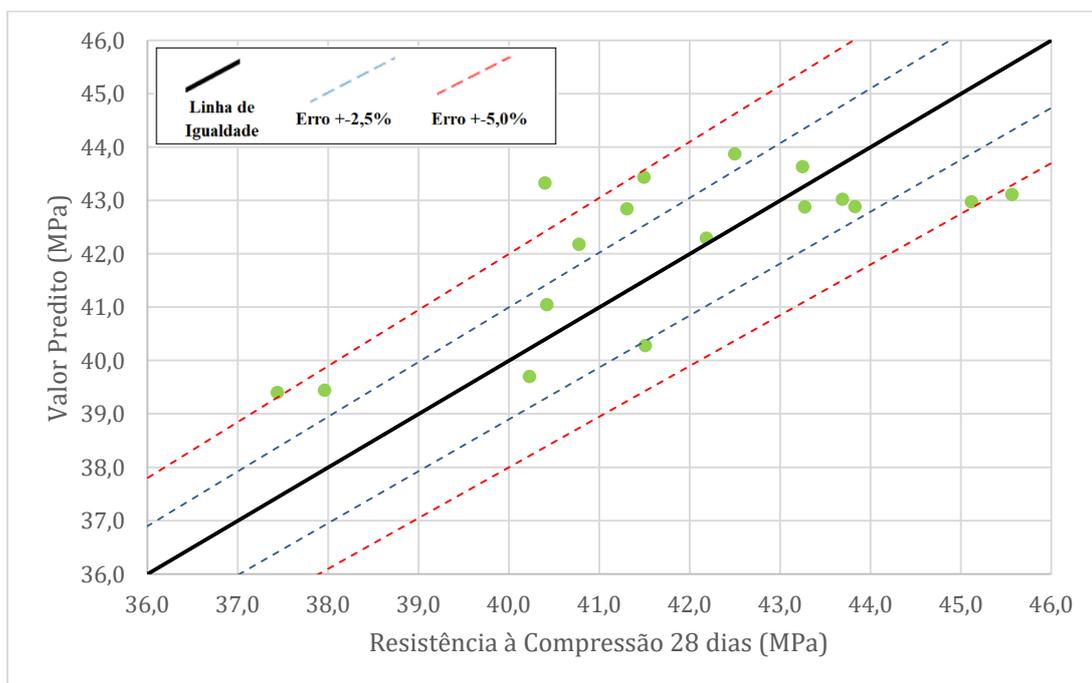


Figura 4.10 - Resultados do Teste do Algoritmo B2

A partir dos dados da apresentados na Tabela 4.11 é possível observar que o modelo proposto apresenta resultados precisos (com baixa dispersão), contudo que não chegam aos valores exatos que deveriam ser previstos. Ou seja, foram detectados muitos erros de previsão, contudo todos com valores baixos (absolutos e relativos). Essa afirmação é confirmada ao analisar os demais parâmetros fornecidos pela Tabela 4.11 e pela Figura 4.11 onde pode-se ver que o ruído apresentado por esses erros é relativamente pequeno.

Tabela 4.11 - Parâmetros do Algoritmo B2 Testado

R ² de Teste	0,51
RMSE de Teste [MPa]	1,513
Erro Absoluto	
Média [MPa]	1,299

Erro Relativo	
MAPE	3,12%
Desvio Padrão	1,88%
Máximo	7,23%
Mínimo	0,24%

Ao se analisar a Tabela 4.11 pode-se notar que foi apresentado um erro absoluto médio de aproximadamente 1,30 MPa. Sabendo que os valores de *output* esperados variam entre 37 e 46 MPa, pode-se assumir que o erro absoluto médio varia entre 3,51% e 2,82% do valor dos *outputs* esperados, valor consideravelmente baixo, que indica certa eficácia na previsão do algoritmo. Corroborando essa afirmação, há os baixos valores de desvio padrão do erro relativo (de 1,88%) e MAPE de 3,12% indicando uma proximidade considerável entre os valores previstos e os valores esperados. Vale apontar ainda que a Tabela 4.11 ainda indica que o erro relativo máximo apresentado foi 7,23%, valor notadamente baixo quando comparado com os demais na Tabela 2.3.

A Figura 4.11 apresenta os resultados de resíduo de erro relativo de cada um dos dados analisados nessa etapa, facilitando a visualização da dispersão dos resultados. Pelo gráfico de resíduo de erro fica nítido que a maior parte dos resultados apresentou no mínimo 1% de erro, o que reforça o valor já apresentado de R^2 de 0,51. Todavia, fica nítido pela figura que os erros apresentados foram todos inferiores a 8%, o que indica uma proximidade relevante dos dados previstos em relação aos dados esperados.

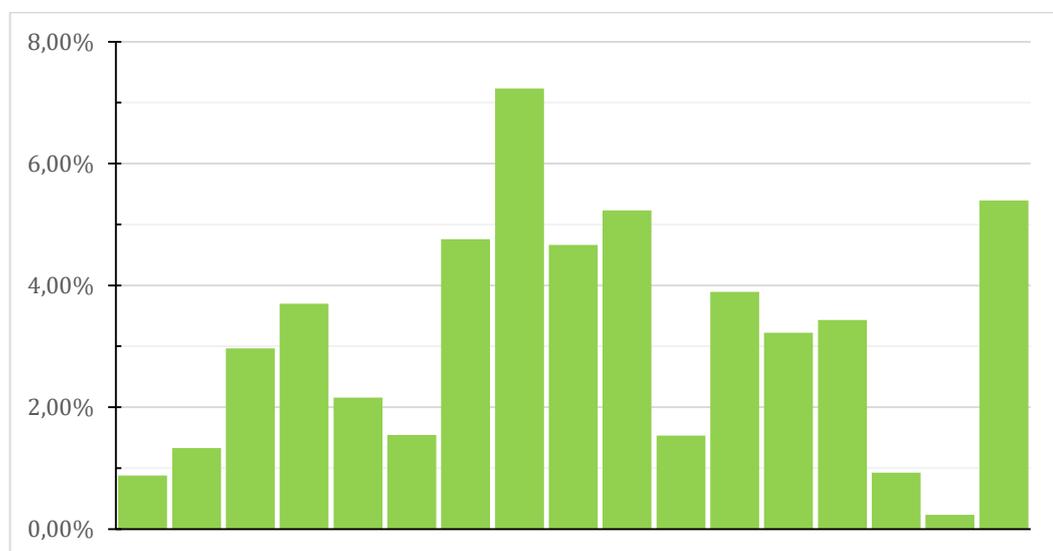


Figura 4.11 - Resíduos de erro relativo nas previsões do algoritmo B2

Desse modo pode-se concluir que a maior parte das previsões feitas durante a fase de teste do modelo não apresentarem os valores esperados, o que se reflete nos valores de erro relativo apresentados na Figura 4.11. Contudo, os *outputs* gerados se concentram fortemente dentro da faixa de até 5% de erro relativo tanto na etapa de treinamento quanto de testes (como pode ser visualizado nas Figura 4.9 e Figura 4.10), o que aponta para uma possível aplicabilidade do modelo para previsões de resistência do CPIV, por mais que o ajuste final do algoritmo não tenha resultado em valores elevados R^2 .

4.2.2.3 ALGORITMO B3

Finalmente, o Banco de Dados B3 foi utilizado para o treinamento e teste de validação do Algoritmo B3. Esse por sua vez não conta com nenhum parâmetro de resistência à compressão como *input*, fato que foi utilizado para avaliar a influência tanto do *input* “Resistência com 1 dia” quanto do “Resistência aos 7 dias” no desempenho das previsões da resistência aos 28 dias. A Figura 4.12 apresenta os resultados do treinamento do algoritmo B3.

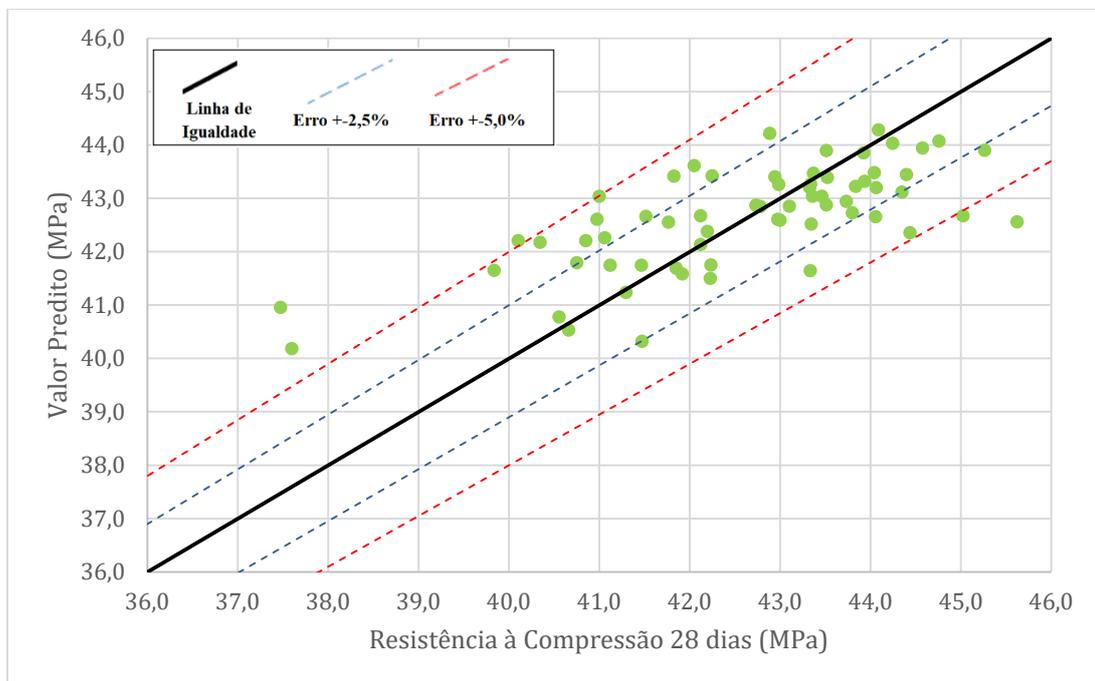


Figura 4.12 - Resultados do Treinamento do Algoritmo B3

Os valores obtidos para R^2 e RMSE foram de respectivamente 0,48 e 1,183 MPa. Estes foram os valores mais desfavoráveis demonstrados entre o treinamento de todos os algoritmos (tipo A e B) produzidos nesse estudo. Apenas as previsões de Asteris et al. (2021)

e Gayathri et al. (2022) com valores de R^2 de 0,378 e 0,46 respectivamente apresentaram desempenho inferior a esse algoritmo.

O valor de RMSE apresentado no treinamento do algoritmo B3 (de 1,183 MPa) foi levemente superior ao apresentado pelo algoritmo A2 em seu treinamento (que também não utiliza *inputs* de resistência à compressão e possui RMSE de 1,174 MPa). Entretanto, assim como para todos os outros 4 algoritmos analisados nesse trabalho, o valor de RMSE de treinamento é considerado baixo quando comparado com algoritmos encontrados no restante da literatura acadêmica (Tabela 2.3).

A Figura 4.13 apresenta os resultados do teste de validação do algoritmo B3. É visualmente claro que há grande dispersão dos dados, o que se traduz numericamente nos parâmetros de qualidade com baixo desempenho vistos na Tabela 4.12.

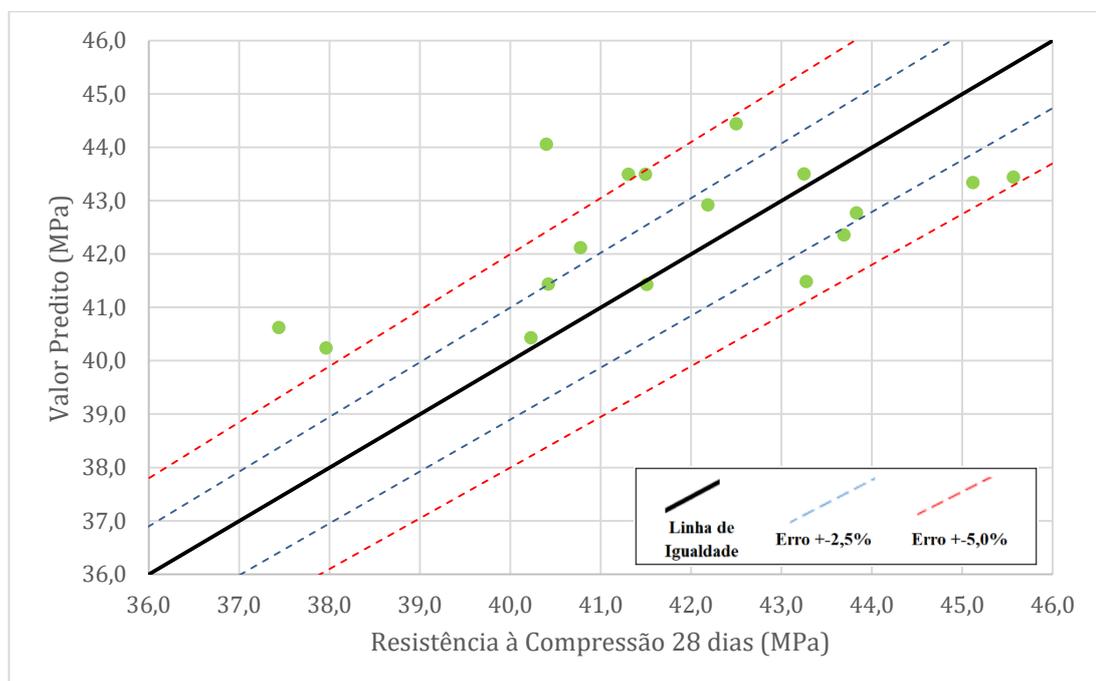


Figura 4.13 - Resultados do Teste do Algoritmo B3

O parâmetro R^2 se apresentou extremamente baixo, inferior aos resultados de todas as outras pesquisas que também trabalham com previsão de resistência à compressão de cimento Portland constantes na Tabela 2.3. O valor de 0,26 indica um ajuste muito pobre do modelo aos dados do subgrupo de teste de validação do algoritmo B3, demonstrando uma baixa habilidade de previsão desse modelo.

Tabela 4.12 - Parâmetros do Algoritmo B3 Testado

R ² de Teste	0,26
RMSE de Teste [MPa]	1,854
Erro Absoluto	
Média [MPa]	1,585
Erro Relativo	
MAPE	3,84%
Desvio Padrão	2,45%
Máximo	9,05%
Mínimo	0,20%

O valor de RMSE apresentado no teste do algoritmo B3 segue o mesmo padrão dos demais casos desse estudo. Ou seja, um valor que comparado com o restante da literatura é baixo indicando um bom desempenho, porém vem acompanhado de um baixo desempenho de R², como já discutido em outras seções desse trabalho.

A elevada dispersão dos resultados é demonstrada por meio dos resultados de erro relativo. Os valores elevados de MAPE, Desvio Padrão do Erro relativo e Erro Relativo Máximo indicam uma grande amplitude de erro, demonstrando a baixa precisão desse modelo específico. Além disso, o erro máximo relativo de 9,05% está muito além dos limites da NBR 7215 (ABNT, 2019) e dos demais erros máximos relativos dos outros algoritmos desse estudo.

Dessa maneira se infere que as previsões feitas durante o teste de validação do modelo B3 não apresentaram desempenho satisfatório (valores baixos de R² e altos de MAPE e erros relativos). Além disso, o valor de R² foi considerado baixo para qualquer padrão de algoritmo de ML, de forma que a dispersão dos dados foi demasiadamente alta.

4.2.2.4 COMPARAÇÃO DE DESEMPENHO

A Tabela 4.13 compila os parâmetros de qualidade dos algoritmos B1, B2 e B3 durante seus testes de validação para fins de comparação. Nota-se inicialmente que o Algoritmo B3 apresentou desempenho inferior aos demais em todos os parâmetros com exceção do erro relativo mínimo.

Tabela 4.13 – Comparação de Parâmetros dos Algoritmos Tipo B

Parâmetros	B1	B2	B3
R ² de Teste	0,40	0,51	0,26
RMSE de Teste [MPa]	1,673	1,513	1,854
Erro Absoluto			
Média [MPa]	1,400	1,299	1,585
Erro Relativo			
MAPE	3,38%	3,12%	3,84%
Desvio Padrão	2,23%	1,88%	2,45%
Máximo	7,71%	7,23%	9,05%
Mínimo	0,25%	0,24%	0,20%

Os resultados deixam claro que a incorporação ou não de *inputs* de resistência à compressão (aos 7 ou 1 dia) interferem consideravelmente no desempenho do algoritmo. Isso pois a grande diferença entre cada um dos 3 algoritmos é o uso ou não desses *inputs*. O R² dos algoritmos B1 e B2 se apresentou, respectivamente, 53,8% e 96,2% maior que o de B3 (que não possui *input* relativo à resistência à compressão). Ou seja, a simples adoção desses *inputs* foi parâmetro crucial para a melhora do desempenho do modelo de ANN. Ressalta-se que no caso a resistência aos 7 dias teve efeito praticamente dobrado em relação ao ganho de desempenho de previsão quando comparada com a resistência com 1 dia.

Esse fato pode ser associado à idade em que o efeito pozolânico da argila calcinada se torna mais evidente. A partir dos 7 dias de idade as reações pozolânicas das argilas calcinadas já se tornaram mais relevantes no ganho de resistência (ANTONI et al., 2012; VASQUES, 2019) e, portanto, aumentam a correlação da resistência dessa idade com a dos 28 dias. Tal fato é inclusive real para as argilas calcinadas da jazida utilizada por essa cimenteira, que foram estudadas por Vasques (2019).

Os valores de RMSE apresentaram resultados similares aos de R² ao se comparar os 3 algoritmos. Ao se analisar apenas esse fator, os melhores desempenho em ordem decrescente foram: B2, B1 e B3. Há menor discrepância entre resultados (chegando a uma diferença de 22,5% entre B2 e B3), contudo esse comportamento também pode ser apontado como um dos efeitos da não adoção de *inputs* relativos à resistência à compressão no algoritmo B3.

Assim como ocorreu com a queda do R² e aumento do RMSE, houve queda da média do erro absoluto, aumentando o desempenho dos algoritmos B1 e B2 em relação ao B3. Por consequência os parâmetros relacionados aos erros relativos também tiveram aumento de

seus desempenhos para esses mesmos modelos. Houve elevação de desempenho de todos os parâmetros com exceção do valor mínimo do erro relativo, o que indica uma maior dispersão dos dados previstos em B3, o que se traduz no valor de R^2 mais baixo.

Fica claro que a incorporação da resistência à compressão com 1 dia como *input* não resulta em grandes elevações no valor de R^2 , assim como ocorreu para os modelos tipo A. Embora o não uso desse *input* seja consideravelmente prejudicial ao modelo para previsão da resistência aos 28 dias. E o mesmo ocorreu para a incorporação da resistência à compressão aos 7 dias, porém em escala mais acentuada.

Dessa forma, levando todos os parâmetros de qualidade em consideração e as análises feitas, o Algoritmo B2 foi definido como o mais eficiente em realizar previsões de resistência à compressão aos 28 dias para o cimento pozolânico analisado utilizando teores de compostos principais do cimento. Isso devido à superioridade de seus parâmetros, que apresentaram menores erros relativos e absolutos e um melhor encaixe do Modelo aos dados de teste.

4.3 ETAPA 03 - COMPARAÇÃO ENTRE MODELOS DE PREVISÃO DA RESISTÊNCIA DO CPIV

Na seção anterior foram definidos os algoritmos com melhor desempenho em cada categoria. Na categoria A (usando teores de óxidos) foi selecionado o algoritmo A1 e na categoria B (usando teores de compostos principais do cimento) foi adotado o modelo B2. Nessa seção esses algoritmos serão mais detalhados e seus desempenhos comparados a fim de se compreender melhor seus comportamentos, e por fim entender qual desses algoritmos apresentou melhor desempenho durante suas previsões em seus bancos de dados.

É importante ressaltar primeiramente que há uma diferença notável entre os Bancos de Dados B2 e A1, a quantidade de conjuntos. Os bancos de dados tipo A apresentam 309 conjuntos de dados enquanto os do tipo B tem 81. Essa diferença pode penalizar os algoritmos do tipo B ao se comparar esses com os do tipo A, e é necessário manter isso em mente durante as discussões desta seção.

O comportamento apresentado pelos modelos A1 e B2 discutidos nas seções anteriores se assemelha em diversos aspectos, contudo é possível notar diferenças relevantes entre estes. A Tabela 4.14 apresenta os parâmetros de qualidade de cada um dos modelos elaborados para fins de comparação em suas etapas de Teste. Essa etapa foi adotada para realizar essas

comparações uma vez que é nela em que os algoritmos realmente apresentam seu potencial total de previsão, uma vez que não tem acesso aos valores de *outputs*, o que não ocorre na etapa de treinamento.

Tabela 4.14 - Parâmetros de Qualidade dos Modelos A1 e B2

Parâmetros	Modelo A1	Modelo B2
R ² de Teste	0,50	0,51
RMSE de Teste [MPa]	1,204	1,513
Média do Erro Absoluto [MPa]	0,98926	1,29887
MAPE	2,36%	3,12%
Desvio Padrão do Erro Relativo	1,65%	1,88%
Erro Relativo Máximo	5,97%	7,23%
Erro Relativo Mínimo	0,18%	0,24%

Nota-se que tanto o Modelo A1 quanto o Modelo B2 apresentaram valores muito próximos de R², a saber, 0,50 e 0,51 respectivamente. Esse fato indica que nenhum dos modelos foi capaz de interpretar a completude dos fatores que influenciam no valor de resistência à compressão aos 28 dias de idade do cimento. Ou seja, os tipos de *input* adotados, seja utilizando teores de óxidos do cimento ou compostos principais do clínquer a partir das fórmulas de Bogue, não foram suficientes para traduzir com exatidão o comportamento de desenvolvimento de resistência do cimento CPIV.

Vale ressaltar que no caso dos modelos tipo A foi adotado o dobro de *inputs* em relação aos modelos tipo B, o que teoricamente tende a reduzir o valor de R². entretanto o modelo A1 ainda conseguiu manter seu R² muito similar ao de B2, indicando seu melhor desempenho no geral, ao se analisar isoladamente esse fator.

Já ao se analisar a Raiz do Erro Quadrático Médio (RMSE) e a Média do Erro Absoluto dos dois modelos nota-se que o Modelo A1 também apresentou melhor desempenho nestes quesitos. Esse fato indica o melhor desempenho geral do primeiro modelo, o que é revalidado ao se analisar os valores de MAPE de cada um dos algoritmos, onde o Modelo A1 apresenta valor de 2,36% e enquanto o segundo possui valor de 3,12% (o que é 33,94% superior ao apresentado pelo algoritmo usando óxidos do cimento). Sabendo que o MAPE é a média do erro relativo de cada uma das amostras, fica claro que a amostra com maior valor deste indicador tende a apresentar maior dispersão dos dados em relação aos valores esperados, o que é corroborado pelos valores de desvio padrão do erro relativo de cada um dos modelos,

que indicam maior desvio para o Modelo B2, conforme pode ser observado ao se comparar a Figura 4.14 com a Figura 4.15.

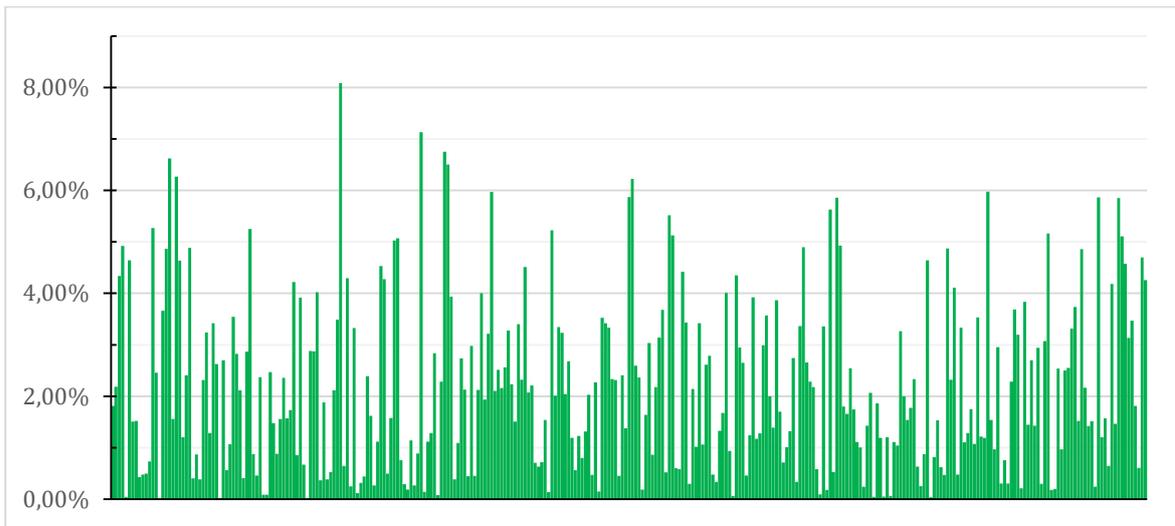


Figura 4.14 - Resíduo do erro relativo de treinamento e teste do Modelo A1

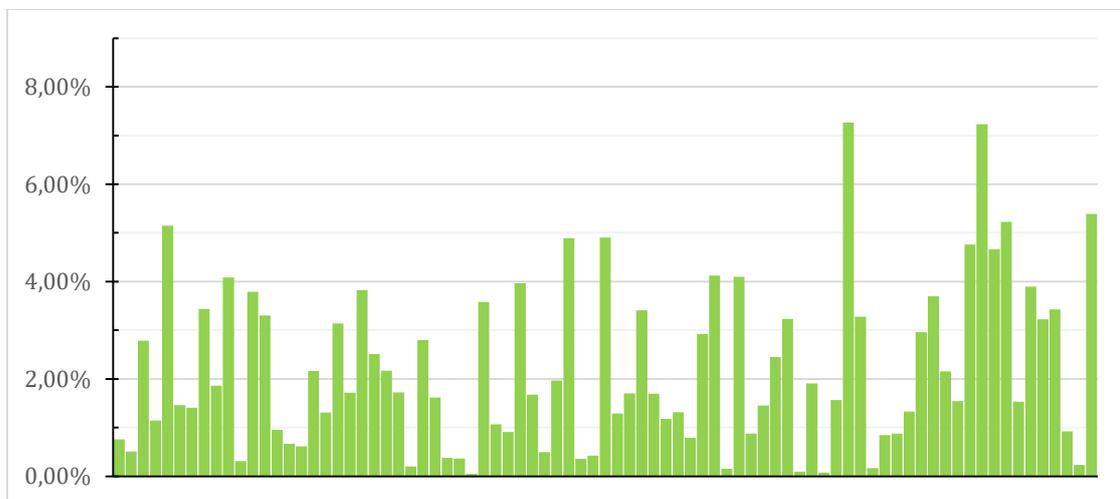


Figura 4.15 - Resíduo do erro relativo do treinamento e teste do Modelo B2

Ao se comparar a Figura 4.14 com a Figura 4.15 pode-se notar que a primeira apresenta um volume muito maior de dados no intervalo de resíduo de erro abaixo de 2,00%. Isso se deve a dois fatores: o primeiro, mais óbvio é o maior de conjunto de dados utilizado no treinamento do algoritmo A1 em relação ao B2; já o segundo fator é o fato de que o Modelo A1 apresenta menores valores de desvio padrão do erro relativo e MAPE inferiores ao do Modelo B2. Esses fatos somados se traduzem visualmente na maior concentração de resíduos de erro em torno de valores inferiores no algoritmo A1 em relação ao algoritmo B2.

Vale ressaltar ainda que segundo a Tabela 4.14 e os resultados apresentados na Figura 4.14 e na Figura 4.15 ambos os modelos desenvolvidos apresentam seus resultados com erros relativos inferiores a 20%. Segundo Chaves (2021) um algoritmo de ML que apresenta esse comportamento tem um erro considerado tolerável na previsão da resistência à compressão de cimentos Portland.

4.3.1 ANÁLISE DO MODELO A1

Ao analisarmos isoladamente os resultados do Modelo A, pode-se concluir que um dos principais fatores responsáveis pelos erros apresentados é o tipo de *input* adotado, ou seja, o uso de teores de óxidos. Isso ocorre devido ao fato de que nesse modelo, praticamente todos os *inputs* se referem à óxidos presentes na composição do cimento CPIV (obtidos por meio de ensaios de FRX). Contudo, esses valores não retratam a reatividade e a real composição química do CPIV, servindo apenas como um indicativo desta. Por advirem de testagem FRX os teores de óxidos não diferenciam os diferentes níveis de organização da estrutura molecular nas amostras (seja ela mais cristalina ou amorfa). Dessa forma amostras com mesmo teor de um certo óxido, porém com configurações espaciais moleculares (e, portanto, reatividade) completamente diferentes podem ser interpretadas como idênticas. Na prática, ao utilizar os *inputs* do Modelo A1, está sendo gerado um algoritmo que não realiza as previsões com a composição química do CPIV de forma direta, mas sim de forma indireta por meio das correlações encontradas pela inteligência artificial entre os teores de óxidos e a resistência aos 28 dias no banco de dados de treinamento. Desse modo, o uso de teores de óxidos como *inputs* pode ser associado ao baixo valor de R^2 e a uma acurácia inferior à esperada (conforme ilustrado na Figura 4.3).

Além disso, a grande uniformidade dos dados apresentados pela cimenteira, e utilizados para produzir a BDG, também é um dos fatores que pode ter penalizado o desempenho dos Modelos A1 e B2. A Tabela 4.15 apresenta parâmetros de desvio padrão, média e a razão entre estes, de cada uma das variáveis (*inputs* e *output*) para os parâmetros utilizados pelos Bancos de Dados do tipo A (com 309 variáveis).

Como já mencionado, todo o banco de dados foi montado a partir de dados fornecidos por uma indústria cimenteira. É esperado que qualquer produto comercial gerado apresente certa uniformidade, com pouca variação, ainda mais os que se caracterizam por procedimentos de natureza industrial. Esse fato se faz marcante na produção do cimento Portland comercial em todo o mundo, processo complexo que precisa ter sua em suas plantas

rigoroso e minucioso controle de produção a fim de que as reações químicas ocorram de maneira desejada (VISED E PECCHIO, 2019). Somado a isso, existem ainda as diversas regulações sobre a produção de cimento Portland, e mais especificamente sobre a produção do CPIV, que definem parâmetros máximos e mínimos de composição e desempenho desse material, de forma que amostras de dois cimentos produzidos em locais diferentes, mas classificados ambos como CPIV tenham desempenho similar (o princípio da similaridade). Todos esses fatores somados resultam na baixa variabilidade dos dados apresentada na Tabela 4.15, o que indica que a indústria em questão tem controle dos processos de produção, conforme esperado (certos dados foram ocultados a fim de manter segredo de produção da cimenteira). Entretanto, é importante ressaltar que a baixa variabilidade em termos puramente numéricos não necessariamente significa uma baixa variabilidade em termos químicos, tal análise será detalhada em etapa posterior deste trabalho (4.3.3).

Tabela 4.15 - Parâmetros da BDG utilizados nos algoritmos de tipo A

Parâmetro	Média	Desvio Padrão	Razão Desvio Padrão/Média
Resistência à Compressão 1 dia (MPa)	13,337	1,86	0,14
Resistência à Compressão 7 dias (MPa)	35,979	2,13	0,06
Resistência à Compressão 28 dias (MPa)	41,984	1,75	0,04
Granulometria na Peneira #200 (%)	4,71	1,76	0,37
Finura Blaine (cm³/g)	5921,23	552,27	0,09
Perda ao Fogo (%)	3,62	0,78	0,22
Resíduo Insolúvel (%)	**	**	**
Teor de Pozolana (%)	**	**	**
CaO (%)	42,16	2,65	0,06
SiO₂ (%)	29,69	1,63	0,05
Al₂O₃ (%)	10,14	1,08	0,11
Fe₂O₃ (%)	2,67	0,13	0,05
MgO (%)	4,30	0,21	0,05
SO₃ (%)	3,81	0,24	0,06
Na₂O (%)	0,17	0,00	0,00

Para fins de previsões a partir de ML essa baixa variabilidade dificulta a capacidade do algoritmo em aprender as correlações entre as diferentes variáveis segundo Oey et al. (2019). A partir disso pode-se concluir que caso todas as classes de *inputs* apresentem magnitudes de variação baixas, todas podem vir a ser consideradas pouco relevantes para a inteligência artificial durante o treinamento, dificultando o processo de aprendizagem do algoritmo e

diminuindo sua eficiência em prever valores corretos. Tal fato ocorreu no caso do banco de dados montado para o Modelo A1 (assim como para o Modelo B2).

Um agravante para esse fator é o fato de que as variações nos teores da composição do CPIV são numericamente baixas, mas suficientemente altas para gerar alterações relevantes na composição química. Ou seja, uma baixa variação em valores absolutos pode resultar em uma mudança total no equilíbrio estequiométrico das reações de hidratação do cimento e posterior formação totalmente diferenciada de compostos do cimento. Entretanto, os modelos de ML foram incapazes de detectar tal processo, avaliando apenas os valores numéricos e não avaliando as implicações químicas resultantes dessas alterações.

Um terceiro fator que pode ter influenciado na performance de ambos os modelos (A1 e B2) é a composição da argila calcinada utilizada no CPIV. Conforme já discutido anteriormente, toda a argila calcinada utilizada no CPIV analisado é produzida a partir de argila natural de uma mesma jazida, porém a composição do material dessa jazida pode variar em seu interior. Dessa forma é possível que existam amostras com argilas calcinadas com reatividades variáveis, porém cada um desses materiais influenciará de forma diferente a resistência à compressão aos 28 dias do CPIV. Contudo, essas nuances e processos não são considerados pelos modelos, que consideram para termos de argila calcinada apenas o teor de substituição, julgando todas as argilas calcinadas utilizadas como um fator único que varia apenas na quantidade acrescida à mistura final do CPIV. Dessa forma, mais uma vez as alterações químicas não são consideradas pelos modelos, sendo levadas em consideração apenas alterações em valores numéricos.

Vale ressaltar que o Modelo A1 utiliza como *inputs* os teores de óxidos do cimento CPIV, ou seja, da mistura de clínquer com argila calcinada. Dessa forma, a composição das argilas calcinadas é levada em consideração pelo algoritmo A1 de forma indireta (por se tratar de teor de óxidos e não de compostos principais), embora de forma subestimada. Além disso, o fato de que a composição das argilas calcinadas está embutida em cada um dos *inputs* que representa um teor de óxido torna em teoria o Modelo A1 mais adequado para cimentos com argilas calcinadas em sua composição. Isso porque foi esse tipo específico de cimento que foi utilizado para treinamento do algoritmo. Entretanto, tal afirmação precisa ser avaliada por meio de uma nova e futura etapa de testes (em um subsequente estudo), dessa vez com uso de dados de outros tipos de cimento Portland e avaliação do desempenho do algoritmo em resposta a esses novos dados.

4.3.2 ANÁLISE DO MODELO B2

O Modelo B2 apresenta os mesmos fatores que influenciam seu desempenho de previsão que o Modelo A1, porém no caso desse segundo modelo há outros fatores que também influenciam seu desempenho fortemente. Um fator que evidentemente influencia o desempenho das previsões do Modelo B2 é o uso dos compostos principais do clínquer calculados pelas fórmulas de Bogue como *inputs*. Isso porque para o uso desses *inputs* foi necessário um processo de conversão da BDG (que utiliza óxidos do cimento CPIV) em um banco de dados com compostos principais do cimento Portland, processo já detalhado anteriormente.

O processo de conversão adotado propaga erros advindos das adaptações das fórmulas de Bogue e da composição das argilas calcinadas. Uma vez que para se obter os teores de óxidos do clínquer, foram necessárias adaptações na real composição das argilas calcinadas de cada amostra, o que inicia um processo de divergência entre os dados reais e os adotados no novo banco de dados. Como esse processo foi aplicado de forma uniforme em todo o a BDG convertida, esse erro se propagou por todos os conjuntos de dados o que gerou uma distorção que em seu estágio final desencadeou uma queda na acurácia do Modelo B2 em relação ao Modelo A1 (com maiores valores de MAPE, Erro médio Absoluto e RMSE). Outra alternativa seria o uso de resultados de quantificação do teor dos compostos do cimento Portland pela técnica de DRX *Rietveld* como *inputs*. Esses dados forneceriam diretamente os teores reais de cada um dos compostos principais, eliminando boa parte das incertezas e erros advindos e propagados do processo de conversão da BDG.

É importante reafirmar que apesar de todos os erros propagados e da consequente maior dificuldade para a interpretação dos dados por parte do algoritmo B2, ainda sim o Modelo B2 apresentou resultados considerados satisfatórios. Isso porque os resultados desse modelo foram consideravelmente próximos aos do Modelo A1, que não contou com o fator extra de incerteza causado pela conversão dos dados. Além disso vale ressaltar que o Banco de Dados B2 é consideravelmente menor que o Banco de Dados A1, fator que influi no processo de aprendizado de cada algoritmo. Sabendo de tudo isso, pode-se assumir que caso se torne possível o acesso a uma composição mais detalhada da argila calcinada utilizada pela empresa (aperfeiçoando o processo de conversão de dados) e a um maior conjunto de dados (aumentando o banco de dados tipo B) seria possível treinar e testar um novo algoritmo do

tipo B que poderia apresentar desempenho superior ao de A1. Entretanto, por conta da natureza dos dados coletados e fornecidos pela cimenteira esse não foi o caso.

4.3.3 ANÁLISE DO EQUILÍBRIO QUÍMICO

Conforme mencionado anteriormente, pequenas variações nos valores de teores de óxidos (e demais parâmetros analisados) podem resultar em grandes variações na composição final do CPIV.

A Tabela 4.16 demonstra a relevância de alguns dos parâmetros analisados na composição final do CPIV estudado. São apresentados 6 casos em que teores de alguns dos parâmetros são detalhados e seguindo a metodologia desse estudo são calculadas suas respectivas composições em termos de compostos principais do cimento. O primeiro caso é nomeado Padrão, a fim de servir de comparação para os demais e exemplifica uma composição hipotética do CPIV, os demais casos são derivações desse, com variações em um ou todos os parâmetros analisados (itens sublinhados).

Tabela 4.16 - Influência dos teores dos parâmetros na composição do CPIV

Caso	Composição CPIV (%)						Composição do Clínquer Calculada (%)			
	Teor de AC	CaO	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	SO ₃	C ₃ S	C ₂ S	C ₃ A	C ₄ AF
Padrão	26,878	42,464	14,517	2,808	1,955	3,700	29,935	19,044	3,724	5,948
Elevação 1%	26,878	<u>42,889</u>	<u>14,662</u>	<u>2,836</u>	<u>1,974</u>	<u>3,737</u>	30,234	19,235	3,761	6,008
Elevação 5%	26,878	<u>44,588</u>	<u>15,243</u>	<u>2,948</u>	<u>2,052</u>	<u>3,885</u>	31,431	19,996	3,910	6,246
CaO em 1%	26,878	<u>42,889</u>	14,517	2,808	1,955	3,700	31,663	17,740	3,724	5,948
Al ₂ O ₃ em 1%	26,878	42,464	14,517	<u>2,836</u>	1,955	3,700	29,746	19,187	3,794	5,948
AC em 2%	<u>27,416</u>	42,464	14,176	2,647	1,941	3,700	33,627	15,281	3,343	5,907

É válido ressaltar que as variáveis apresentadas na Tabela acima fazem referência à composição do CPIV e representam cerca de 87% da totalidade da composição de cada amostra. Outros componentes (como impurezas, Na₂O, K₂O, MgO entre outros) não são apresentados nessa tabela e chegam a corresponder a valores entre 7,6% e 13% da composição total do CPIV. Sabendo disso, se passa a analisar os demais casos apresentados na Tabela 4.16, onde uma elevação nos teores de componentes apresentados na tabela será compensada por uma redução nos teores dos outros componentes secundários não apresentados nessa tabela.

O segundo caso analisado na Tabela 4.16 apresenta a variação uniforme dos parâmetros analisados (com exceção do teor de AC) em 1%. Essa elevação é bastante comum na BDG, sendo inferior à praticamente todas às variações apresentadas pelas variáveis na Tabela 4.15. Nota-se que nesse caso, onde a diferença numérica é muito baixa para os teores de óxidos, já se identificam mudanças proporcionais (em 1%) para os compostos principais. O mesmo se observa no caso análogo “Elevação 5%”, valor que também se encontra abaixo das variações na Tabela 4.15. Sabendo disso, é possível observar que uma pequena variação nesses parâmetros gera variações que repercutem nos teores de óxidos principais e que certamente afetarão o equilíbrio estequiométrico durante a hidratação do cimento. Consequentemente, a formação dos produtos de hidratação será afetada, gerando uma microestrutura diferenciada e por fim uma resistência à compressão que poderá diferir consideravelmente entre tais casos.

Já ao analisarmos o caso seguinte na Tabela 4.16, “CaO em 1%”, que conta com a elevação em 1%, apenas do teor de CaO em relação ao Caso Padrão, é ilustrada a influência desse fator isoladamente. Uma elevação de 1% nesse parâmetro resultou na variação dos teores de alita e belita em +5,78% e -6,85% respectivamente, fato que isoladamente já demonstra que a mudança de uma única variável em valor numérico considerado baixo, gera considerável alteração nos teores de compostos principais. Tal fato resultará ultimamente na variação dos produtos de hidratação e da resistência à compressão da mistura, conforme já explicitado anteriormente. O caso “Al₂O₃ em 1%” se comporta de forma análoga ao caso já analisado, com variações em todos os teores com exceção do de C₄AF.

Por fim, o último caso varia unicamente o teor de AC em 2% em relação ao traço padrão, o que por consequência altera todo o processo de conversão de óxidos em compostos principais. Essa alteração foi a que gerou maiores variações nos teores de compostos principais, gerando variações em valores de até 19,76% nos teores dos compostos principais do CPIV, fato que indica uma certa variação no comportamento mecânico da mistura depois de hidratada.

Ainda é possível concluir por meio do exemplo que um dos fatores com maior influência na variação da composição química do CPIV analisado é o teor de AC. Tal fato condiz com a natureza mais variável desse material (natural) em comparação com o clínquer (industrial). Esse comportamento inclusive corrobora a decisão da indústria cimenteira em não divulgar os valores de AC incorporada em seus traços. Analogamente, o teor de Resíduo Insolúvel (que advém diretamente do teor de AC) também influencia diretamente na variação

da composição do CPIV e em seu desenvolvimento de resistência após hidratado, assim como ocorre com a AC.

Dessa forma fica ilustrado como um valor considerado baixo em termos puramente numéricos pode resultar em grande variação em termos de composição química. Torna-se claro que uma análise unicamente numérica dos parâmetros (como a realizada pelos algoritmos A1 e B2) não é capaz de reconhecer os comportamentos mecânicos e químicos da hidratação do cimento Portland. Tal fato penaliza o desempenho de modelos de ML que tentem prever a resistência do CPIV, como os modelos A1 e B2 nesse trabalho.

4.3.4 AVALIAÇÃO DO ALGORITMO MAIS ADEQUADO

Todos os indicadores apontam para o melhor desempenho do uso de teor de óxidos (Modelo A1) em relação ao uso dos compostos principais (Modelo B2) obtidos por meio das fórmulas de Bogue. Isso devido ao fato de que no caso do segundo modelo, há uma propagação das incertezas e erros contidos no banco de dados A1 para o banco de dados B2, e esta é somada a erros que se originam no processo de conversão dos dados em compostos principais.

Além disso, pode-se argumentar que o maior banco de dados do Modelo A1 (309 conjuntos no Modelo A1 contra 81 do modelo B2) pode ter tornado o algoritmo A1 mais capacitado para realizar previsões do que sua contraparte B2. A fim de se avaliar efetivamente qual dos modelos apresentará definitivamente melhor desempenho seria necessário o uso de dois bancos de dados de mesmo tamanho, fato que se tornou inviável no caso dos dados fornecidos devido à falta de análise constante da composição da argila calcinada utilizada no CPIV que resultou em incertezas no processo de conversão de dados e consequente diminuição na quantidade de conjuntos dos bancos de dados do tipo B.

Por fim se destaca que o uso dos *inputs* de resistência à compressão a 1 e 7 dias foram benéficos para o desempenho das previsões dos modelos A1 e B2. O efeito aparente do *input* relacionado à resistência aos 7 dias é maior, contudo, há um contraponto logístico, uma vez que na prática esse parâmetro demora uma semana para estar disponível, consumindo um tempo considerável ao se comparar com o parâmetro resistência de 1 dia. Dessa forma é preciso analisar com cautela a aplicação do modelo quando este for adotado, para se avaliar corretamente se o ganho de desempenho do algoritmo com esse *input* compensa o tempo

demandado de espera para se alimentar o modelo, quando comparado com a resistência de 1 dia.

5 CONCLUSÕES

A partir dos procedimentos realizados foi possível avaliar o desempenho e aplicabilidade do uso de técnicas de *Machine Learning*, mais especificamente *Multiplayer Perceptrons Artificial Neural Networks*, para a previsão de resistência à compressão aos 28 dias do CPIV. A partir de dados fornecidos por uma cimenteira, foi possível montar cinco bancos de dados, dois deles utilizando teores de óxidos (tipo A) e 3 adotando compostos principais como *inputs* (tipo B), cada categoria contendo 309 e 81 conjuntos de dados, respectivamente. Esse trabalho optou por utilizar apenas dados de obtenção relativamente fácil e que já são emitidos durante os ensaios de controle de produção do cimento Portland como *inputs* para a previsão de sua resistência à compressão. Tal estratégia difere das demais pesquisas encontradas na literatura científica ou até no meio comercial nacional, que optam por utilizar outros tipos de características do cimento como *inputs* para a previsão da resistência à compressão do cimento (parâmetros de fabricação do clínquer, peso específico do clínquer puro, temperatura de forno, tempo de queima, composição advinda de dados de testes de DRX *Rietveld*). A partir dos resultados obtidos foi possível chegar às seguintes conclusões:

- Foi possível montar uma Base de Dados Geral (BDG) com todos os parâmetros fornecidos pela cimenteira. A partir dessa foram montados 5 bancos de dados diferentes para cada um dos algoritmos propostos nesse estudo. Contudo, para os Bancos de Dados do tipo B, seria recomendável um banco maior (com mais conjuntos de *inputs*). Isso para que seja mais eficiente o uso das conversões de Bogue para estimativa dos teores dos compostos principais do cimento;
- Foi efetuada a previsão da resistência à compressão do CPIV por meio de algoritmos com teores de óxidos como *inputs*, e se chegou a conclusão que o algoritmo A1 apresentou melhor desempenho. Este conseguiu realizar previsões de resistência à compressão com erros relativos inferiores a 5,97%, MAPE de 2,36%, RMSE de 1,204 MPa e erro absoluto máximo de 0,989 MPa. Já o valor de R^2 apresentado foi de 0,50, resultado que indica certa dificuldade do modelo em abordar todos os processos que influenciam no valor do *output*, contudo ainda assim o algoritmo foi capaz de realizar previsões com baixos valores de erros relativos e absolutos, conforme comprovados pelos demais parâmetros de qualidade.

- O algoritmo B2 foi selecionado entre os modelos que utilizaram teores de compostos principais para prever a resistência do cimento CPIV como o de melhor desempenho. Esse algoritmo apresentou erro relativo máximo de 7,23%, MAPE de 3,12%, RMSE de 1,513 MPa, erro absoluto máximo de 1,298 MPa e R^2 de 0,51. A conversão dos dados em teores de compostos principais claramente afetou o desempenho do algoritmo devido às incertezas advindas do processo de conversão e da composição da argila calcinada contida no cimento pozolânico. Contudo, ainda assim o desempenho foi próximo ao de A1 e com valores de erros considerados baixos ao se comparar a literatura existente, indicando boa acurácia do modelo.
- Se constatou que a adoção de resistência à compressão com 1 e 7 dias de idade como *inputs* tende a influenciar positivamente no desempenho dos algoritmos. Se constatou que o efeito se dá de forma mais intensa quando da adoção do *input* “resistência aos 7 dias”.
- Após análise se constatou que o Modelo A1 apresentou melhor desempenho que o Modelo B2. Fato que se deu pela maior propagação de erros no algoritmo B2 em relação ao A1, o que afetou o desempenho desse. Além disso, possivelmente o maior banco de dados do Modelo A1 pode ter contribuído para o melhor processo de aprendizagem desse algoritmo. Contudo, fora esses fatos ainda pode-se ressaltar que o uso dos teores de óxidos apresenta uma maior comodidade em relação ao uso dos teores de compostos principais, por não necessitar do processo de conversão e ainda assim apresentar desempenho superior ao Modelo B2;

Ambos os modelos elaborados apresentaram um erro sistêmico em maior ou menor grau e valores de R^2 que podem ser considerados baixos, entretanto ainda assim são considerados eficientes. Isso devido aos demais parâmetros que comprovam seu desempenho na previsão da resistência à compressão, sempre com erro relativo inferior a 8%. Além disso, o uso de *inputs* que podem ser obtidos com ensaios de relativamente fácil acesso, baixo custo e praticamente expeditos facilitam o processo de alimentação dos algoritmos e antecipação do resultado da resistência aos 28 dias, em contraste com os sistemas que se encontram no meio comercial atual que demandam ensaios de alto custo e difícil acesso. Os baixos valores de R^2 dos modelos desenvolvidos podem aparentar indicar baixa eficiência de previsão destes,

porém após análise mais aprofundada foi possível notar que foram capazes de previsões com precisão aceitável e utilizável (devido aos parâmetros MAPE, RMSE, e erros relativos baixos). Dessa forma, ainda que a precisão dos modelos elaborados nesse trabalho seja inferior ao de modelos que usam dados advindos dos resultados de *DRX-rietveld* como *inputs*, os modelos tanto do tipo A quanto B podem vir a se tornar competitivos em termos de previsão com as devidas adaptações.

Analisando todos os fatores apresentados é possível chegar à conclusão que ambos os modelos elaborados foram capazes de gerar previsões com uma margem de erro tolerável abaixo de 20% de erro relativo nos resultados, assim como no caso do algoritmo treinado para previsão de resistência à compressão de CPI por Chaves (2021). Apesar do indicador R^2 aparentar performar abaixo das expectativas, outros indicadores (como RMSE, MAPE e Erro Absoluto Médio) demonstraram resultados melhores do que grande parte da literatura analisada.

A partir de tudo isso se pode concluir que foi possível realizar previsões aceitáveis da resistência do CPIV por meio dos dois modelos de ML elaborados por meio da técnica de ANN. Apesar de ambos os modelos não conseguirem abordar a completude dos parâmetros que realmente influenciam na resistência à compressão aos 28 dias, o desempenho na previsão dessa propriedade foi consideravelmente elevado, podendo ser considerado viável para diversas aplicações como laboratórios, estudos e sinalizador de controle de produção.

5.1 RECOMENDAÇÕES PARA PESQUISAS FUTURAS

A partir dos resultados e discussões levantadas nesse trabalho, recomenda-se que se abordem os seguintes assuntos em futuras pesquisas que desejem continuar esse estudo:

- O treinamento de novos algoritmos em bancos de dados mais arrojados (principalmente no caso do algoritmo B), com maior número de amostras e maior controle sobre a composição química das argilas calcinadas;
- Produção de novos algoritmos em bancos de dados utilizando parâmetros de fabricação do cimento (como tempo no forno, peso do clínquer, temperatura de queima) para previsão da resistência do cimento produzido;

- Previsão de outras propriedades do cimento Portland pozolânico por meio dos parâmetros disponíveis na BDG. Tais como tempos de início e fim de pega e resistências aos 3 e 7 dias de idade;
- Aplicação de modelos de previsão com os mesmos tipos de *input* para outras classes de cimento Portland, como o CPV, CPIII e CPII-Z;
- Comparação do desempenho dos algoritmos elaborados nesse trabalho (com uso de óxidos ou uso de compostos principais calculados a partir desses) com os modelos que utilizam resultados de DRX-Rietveld como *inputs* a fim de se avaliar a real diferença entre os modelos;

REFERÊNCIAS

ABNT, Associação Brasileira de Normas Técnicas. **NBR 7215: Cimento Portland – Determinação da resistência à compressão**. Rio de Janeiro, 2019.

ABNT, Associação Brasileira de Normas Técnicas. **NBR 11579: Cimento Portland — Determinação do índice de finura por meio da peneira 75 µm (nº 200)**. Rio de Janeiro, 2012.

ABNT, Associação Brasileira de Normas Técnicas. **NBR 16372: Cimento Portland e outros materiais em pó — Determinação da finura pelo método de permeabilidade ao ar (método de Blaine)**. Rio de Janeiro, 2015.

ABNT, Associação Brasileira de Normas Técnicas. **NBR 12653: Materiais Pozolânicos – Requisitos**. Rio de Janeiro, 2015.

ABNT, Associação Brasileira de Normas Técnicas. **NBR 16606: Cimento Portland — Determinação da pasta de consistência normal**. Rio de Janeiro, 2018.

ABNT, Associação Brasileira de Normas Técnicas. **NBR 16607: Cimento Portland — Determinação dos tempos de pega**. Rio de Janeiro, 2018.

ABNT, Associação Brasileira de Normas Técnicas. **NBR 16697: Cimento Portland — Requisitos**. Rio de Janeiro, 2018.

ABNT, Associação Brasileira de Normas Técnicas. **NBR NM 15: Cimento Portland — Análise química - Determinação de resíduo insolúvel**. Rio de Janeiro, 2012.

ABNT, Associação Brasileira de Normas Técnicas. **NBR NM 18: Cimento Portland — Análise química - Determinação de perda ao fogo**. Rio de Janeiro, 2012.

ABIDIN, C.; DEMIRHAN, S.; TEKIN, R. **Comparison of different machine learning methods for estimating compressive strength of mortars**. Construction and Building Materials, Vol. 335, 2022.

ADEL, H.; PALIZBAN, S.M.M.; SHARIFI, S.S.; GHAZAAN, M.I.; KORAYEM, A.H. **Predicting mechanical properties of carbon nanotube-reinforced cementitious nanocomposites using interpretable ensemble learning models**. Construction and Building Materials, Vol. 354, 2022.

ALKADHIM, H.A.; AMIN, M.N.; AHMAD, W.; KHAN, K.; NAZAR, S.; FARAZ, M.I.; IMRAN, M. **Evaluating the strength and impact of raw ingredients of cement mortar incorporating waste glass powder using Machine Learning and shapley additive explanations (SHAP) methods**. Materials, Vol. 15, 2022.

AL-HASANI, L.E.; PEREZ, G.; HERNDON, H.N.; PARK, J.; POOLE, J.L.; TIEN, I.; WASHBURN, N.R.; CHO, Y.K.; GENTRY, T.R.; KURTIS, K.E. **Prediction of heat of hydration of cementitious systems using Gaussian process regression enables mass concrete thermal modeling**. Mater. Struct. Vol. 56, (2023).

ANDRADE, D. S. **Microestrutura de pastas de cimento Portland com nanossílica coloidal e adições minerais altamente reativas**. Tese de Doutorado em Estruturas e Construção Civil, 0004/17, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 319p, 2017.

ANTONI, M.; ROSSEN, J.; MARTIRENA, F.; SCRIVENER, K. **Cement substitution by a combination of metakaolin and limestone**. Cement and Concrete Research, Elsevier, v. 42, n. 12, p. 1579–1589, 2012.

AMER, A. A.; EL-HOSEN, S. **Properties and performance of metakaolin pozzolanic cement pastes**. Journal of Thermal Analysis and Calorimetry, 129(1), 33–44, 2017.

ARAMBURO, C.; PEDRAJAS, C.; RAHHAL, V.; GONZÁLEZ, M.; TALERO, R. **Calcined clays for low carbon cement: Rheological behaviour in fresh Portland cement pastes**. Materials Letters, 239, 24–28, 2019.

ASFORA, V., K. **Fluorescência de raios X por dispersão de energia aplicada à caracterização de tijolos de sítios históricos de Pernambuco**. Universidade Federal de Pernambuco, Recife, Brasil, 2010.

ASTERIS, P.G.; KOOPALIPPOOR, M.; ARMAGHANI, D.J. et al. **Prediction of cement-based mortars compressive strength using machine learning techniques**. Neural Comput & Applic, 2021.

BANSAL, T.; TALAKOKULA, V.; SATHUJODA, P. **Machine learning-based monitoring and predicting the compressive strength of different blended cementitious systems using embedded piezo-sensor data**. Measurement, Volume 205, 2022.

BATTAGIN, A. **As adições como substitutos do clínquer no contexto do Projeto Cement Technology Roadmap 2050**. 7º Congresso Brasileiro do Cimento. São Paulo. 2016.

BEDIAKO, M.; PUROHIT, S. S.; KEVERN, J. T. **Investigation into Ghanaian calcined clay as supplementary cementitious material**. ACI Materials Journal, Vol. 114, No. 6, 2017.

BEHNOOD, A.; VERIAN, K.P.; GHAREHVERAN, M.M. **Evaluation of the splitting tensile strength in plain and steel fiber-reinforced concrete based on the compressive strength**, Constr. Build. Mater. 98, 2015.

BEN CHAABENE, W.; FLAH, M.; NEHDI, M. L. **Machine learning prediction of mechanical properties of concrete: Critical review**. Construction and Building Materials, v. 260, 2020.

BERNAL, S.A.; JUENGER, M.C.G.; KE, X.; MATTHES, W.; LOTHENBACH, B.; DE BELIE, N.; PROVIS, J.L. **Characterization of supplementary cementitious materials by thermal analysis**. Mater. Struct. 50, 1–13, 2016.

BULLARD, J. W.; GARBOCZI, E. J.; STUTZMAN, P. E.; FENG, P.; BRAND, A. S.; PERRY, L.; TERRILL, J. E. **Measurement and modeling needs for microstructure and reactivity of next-generation concrete binders**. Cement and Concrete Composites, 2017.

CEMBUREAU – **THE EUROPEAN CEMENT. Activity Report 2020**. Disponível em: <<https://cembureau.eu/media/m2ugw54y/cembureau-2020-activity-report.pdf>>. Acessado em: 02 set. 2021, (2021).

CHAVES, J. F. N. (2021). **Previsão da resistência à compressão do cimento Portland comum com utilização de técnica de Machine Learning**. Dissertação de Mestrado em Estruturas e Construção Civil, Publicação DM – 03A/22, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 116p.

COOK, R.; HAN, T.; CHILDERS, A.; RYCKMAN, C.; KHAYAT, K.; MA, H.; HUANG, J; KUMAR, A. **Machine learning for high-fidelity prediction of cement hydration kinetics in blended systems**. Materials & Design, 208, 109920, 2021.

DE LA VARGA, I.; CASTRO, J.; BENTZ, D. P.; ZUNINO, F.; WEISS, J. **Evaluating the hydration of high volume fly ash mixtures using chemically inert fillers**. Construction and Building Materials, Vol. 161, pp. 221-228, 2018.

GAYATHRI, R.; CEPOVÁ, L.; RAJESH, M.; KALITA, K.A. **Comparative Analysis of Machine Learning Models in Prediction of Mortar Compressive Strength**. Processes, vol. 10, 2022.

GÉRON, A. **Hand-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems**. 2. ed. O'Reilly, 2019.

Gobbo, L. de A. (2009) **Aplicação da difração de raios-X e método de Rietveld no estudo de Cimento Portland**. M. Thesis. Instituto de Geociências, Universidade de São Paulo.

HAN, Q.; GUI, C.; XU, J.; LACIDOGNA, G. **A generalized method to predict the compressive strength of high-performance concrete by improved random forest algorithm**, Constr. Build. Mater., 2019.

HONG, K.; JUSTNES, H.; GEIKER, M. **Early age strength increase of fly ash blended cement by a ternary hardening accelerating admixture**, Cem. Concr. Res. 81, 59–69, <https://doi.org/10.1016/j.cemconres.2015.11.004>, 2016.

HUANG, J. S.; LIEW, J. X.; LIEW, K. M. **Data-driven machine learning approach for exploring and assessing mechanical properties of carbon nanotube-reinforced cement composites**. Composite Structures, 267, 113917, 2021.

HUANG, J.; ZHOU, M.; YUAN, H.; SABRI, M.M.S.; LI, X. **Prediction of the compressive strength for cement-based materials with metakaolin based on the hybrid Machine Learning method**. Materials, Vol. 15, 2022.

IEA. **Cement**, IEA, Paris, <https://www.iea.org/reports/cement> Acessado em 15/08/2021, 2020.

KHATIB, J. M.; WILD, S. **Sulphate resistance of metakaolin mortar**. *Cem Concr Res* 28(1):83–92, 1998.

KONSTANTOPOULOS, G.; KOUMOULOS, E.P.; CHARITIDIS, C.A. **Testing Novel Portland Cement Formulations with Carbon Nanotubes and Intrinsic Properties Revelation: Nanoindentation Analysis with Machine Learning on Microstructure Identification**. *Nanomaterials*, Vol. 10, p. 645, 2020.

KUMAR, N; NARANJE, V. "**Prediction of Cement Strength using Machine Learning Approach**," 2019 Amity International Conference on Artificial Intelligence (AICAI), pp. 239-243, 2019.

KUMAR, N; NARANJE, V.; SALUNKHE, S. **Cement strength prediction using cloud-based machine learning techniques**. *Journal of Structural Integrity and Maintenance*, 5:4, 244-251, 2020.

LI, Y.; LI, H.; JIN, C.; SHEN, J. **The study of effect of carbon nanotubes on the compressive strength of cement-based materials based on machine learning**. *Construction and Building Materials*, Vol. 358, 2022.

LINS, D. N. **Análise da Resistência à Compressão do cimento LC³ e a influência das adições minerais em seu desempenho**. Dissertação de Mestrado em Estruturas e Construção Civil, Publicação E.DM-29A/17, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 141p, 2017.

LHENE, J.; PRESTON, F. **Making Concrete Change - Innovation in low-carbon Cement and Concrete**. Chatam House Report. Chatam House, the Royal Institute of International Affairs. ISBN 978 1 78413 272 9. Londres, 2018.

Ma, H.; Liu, J.; Zhang, J.; Huang, J. **Estimating the Compressive Strength of Cement-Based Materials with Mining Waste Using Support Vector Machine, Decision Tree, and Random Forest Models**. *Advances in Civil Engineering*, Vol. 2021, 2021.

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

MARAGHECHI, H.; AVET, F.; SCRIVENER, K. **Chloride transport behavior of LC3 binders**. in: F. Martirena, A. Favier, K. Scrivener (Eds.), *Calcined Clays for Sustainable Concrete*, vol. 16, Springer Netherlands, Dordrecht, pp. 306e309, 2018.

MARANI, A.; NEHDI, M. L. **Machine learning prediction of compressive strength for phase change materials integrated cementitious composites**. *Construction and Building Materials*, 265, 120286, 2020.

MEHTA P. K.; MONTEIRO P. J. M. **Concreto. Microestrutura, Propriedades e Materiais**. 2 ed. São Paulo, IBRACON., 782 p., 2014.

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

MURAT, M. **Hydration reaction and hardening of calcined clays and related minerals. I. Preliminary investigation on metakaolinite**. *Cem Concr Res*. Vol.13, pp 259–66, 1983.

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

OEY, T.; JONES, S.; BULLARD, J.W.; SANT, G. **Machine learning can predict setting behavior and strength evolution of hydrating cement systems**. *J Am Ceram Soc*; 103:480–490, 2020.

OZCAN, G.; KOCAK, Y.; GULBANDILAR, E. **Estimation of compressive strength of BFS and WTRP blended cement mortars with machine learning models**. *Computers and Concrete*, 19(3), 275–282, 2017

PALACIOS, M.; HADI, K-K.; MANTELLATO, S.; BOWEN, P. **Laser diffraction and gas adsorption techniques**. In: **A Practical Guide to Microstructural Analysis of Cementitious Materials**. [s.l.] CRC Press, 2016.

PINHEIRO, D. G. L. **Microestrutura de pastas de cimento com adição de argila calcinada e nanossílica**. Qualificação de Doutorado em Estruturas e Construção Civil. Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 45p, 2018.

REZA, S.; ZHANG, X.; MAHDIYAR, A. **Neurocomputing A comprehensive review on the application of artificial neural networks in building energy analysis**, *Neurocomputing*. 340 55–75, 2019.

ROCCHI, A.C.N.L.; OLIVEIRA, J.M. **Avaliação da resistência à compressão de argamassas com o uso de cimento LC3 com diferentes proporções de filer calcário e argila calcinada**. Monografia de Projeto Final, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 80 p, 2017.

SABIR, B. B.; WILD, S.; BAI, J. **Metakaolin and calcined clays as pozzolans for concrete: a review**. *Cement and concrete composites*. Vol 23, 6 ed. pp 441-454, 2001.

SCRIVENER, K. L. **Options for the future of cement**. *Indian Concrete*. Journal, v. 88, n. 7, p. 11-21, 2014.

SCRIVENER, K. L.; OUZIA, A.; JUILLAND, P.; MOHAMED, A. K. **Advances in understanding cement hydration mechanisms**. *Cement and Concrete Research*, v. 124, 2019.

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

SHANMUGASUNDARAM, N.; PRAVEENKUMAR, S.; GAYATHIRI, K.; DIVYA, S. **Prediction on compressive strength of Engineered Cementitious composites using Machine learning approach.** Construction and Building Materials, Vol. 342, 2022.

SHI, X.C.; DONG, Y.F. **Support Vector Machine Applied to Prediction of Strength of Cement.** Department of civil engineering, Henan University of technology, Zhengzhou, Henan, China, 2011.

SNIC. **Resultados Preliminares de Junho de 2021.** <http://snic.org.br/numeros-resultados-preliminares-ver.php?id=63> Acessado em 01/09/2021, 2021.

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

SOUZA, A. C. R. R. **Análise estatística da produção de cimento no Brasil e sua relação com o PIB da construção civil.** Universidade Federal de Ouro Preto, Programa de Pós Graduação em Engenharia das Construções. 2021.

TIRONI, A.; TREZZA M. A.; SCIAN A. N.; IRASSAR E. F. **Thermal analysis to assess pozzolanic activity of calcined kaolinitic clays.** J Therm Anal Colorim. 117:547-556, 2014.

TIRONI, A., SCIAN, A. N.; IRASSAR, E. F. **Blended Cements with Limestone Filler and Kaolinitic Calcined Clay: Filler and Pozzolanic Effects.** Journal of Materials in Civil Engineering, 29(9), 04017116, 2017.

TURK, K.; KINA, C.; TANYILDIZI, H. **Extreme Learning Machine for Estimation of the Engineering Properties of Self-Compacting Mortar with High-Volume Mineral Admixtures.** Iran J. Sci. Technol. Trans. Civ. Eng., (2023).

VAKHARIA, V.; GUJAR, R. **Prediction of compressive strength and portland cement composition using cross-validation and feature ranking techniques.** Construction and Building Materials, 225, 292–301, 2019.

VASQUES, L.P. **Influência da substituição do cimento Portland por Argilas Calcinadas na resistência à compressão de argamassas.** Monografia de Projeto Final, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 82 p, 2019.

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

WANG, Y.; YE, G.; VAN BRENGEL, K. **Microstructure of cement paste blended with micronized sand (MS)**. Durability of Building Materials and Components, Building Pathology and Reahabilitation 3, pp. 61-84, 2013.

YANGUATIN, H.; TOBÓN, J.; RAMÍREZ, J. **Reactividad puzolánica de arcillas caoliníticas una revisión**. Revista Ingeniería de Construcción, Vol. 32, pp. 13-24, 2017.

YOUNG, B. A.; HALL, A.; PILON, L.; GUPTA, P.; SANT, G. **Can the compressive strength of concrete be estimated from knowledge of the mixture proportions?: New insights from statistical analysis and machine learning methods**. Cement and Concrete Research, Volume 115, Pages 379-388, ISSN 0008-8846, 2019.

ZHANG, J.; MA, G.; HUANG, Y.; SUN, J.; ASLANI, F.; NENER, B. **Modelling uniaxial compressive strength of lightweight self-compacting concrete using random forest regression**, Construction Building Materials. 210, 713–719, 2019.

ZHANG, J.; NIU, W.; YANG, Y.; HOU, D.; DONG, B. **Machine learning prediction models for compressive strength of calcined sludge-cement composites**. Construction and Building Materials, vol. 346, 2022.

APÊNDICE A – BASE DE DADOS GERAL

R. COMP. 1 DIA	R. COMP. 3 DIAS	R. COMP. 7 DIAS	R. COMP. 28 DIAS	ÁGUA CONSISTÊNCIA NORMAL	TEMP O INICIO PEGA	TEMP O FIM DE PEGA	GRANULOMETRIA #200	BLAINE	PERDA AO FOGO	RESÍDUO INSOLÚVEL	% Pozolana	CaO (%)	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)	MgO (%)	SO ₃ (%)	Na ₂ O (%)	K ₂ O (%)
17,265	28,803	36,543	45,248	34,2	140	215	1,6	5485	2,72			43,98	31,07	9,07	2,58	4,38	3,91	0,17	0,69
16,245	28,375	38,200	42,220	34,2	135	210	2,29	5265	2,59			42,68	31,87	9,52	2,56	4,22	3,70	0,17	0,69
17,648	28,640	37,780	40,950	34,2	135	210	2,74	5084	2,27			44,72	30,83	9,02	2,65	4,29	3,77	0,17	0,69
17,458	29,528	38,083	43,708	34,2	140	215	2,56	5085	2,27			44,26	31,04	9,21	2,65	4,28	3,85	0,17	0,69
18,218	28,598	37,053	44,520	34,6	145	215	1,88	5367	2,39			43,89	30,58	9,05	2,61	4,33	3,84	0,17	0,69
16,503	28,820	35,970	43,890	34,6	140	210	2	5368	2,3			42,64	31,99	9,67	2,59	4,2	3,84	0,17	0,69
18,400	30,060	39,015	43,640	34,8	145	215	1,93	5476	2,72			42,5	31,78	9,52	2,59	4,25	3,78	0,17	0,69
16,163	27,423	37,353	41,140	33,4	135	210	1,99	5260	3,36			42,19	31,24	9,62	2,57	4,42	3,76	0,17	0,69
17,280	27,605	37,900	42,285	33	130	205	1,99	5305	3,12			42,52	31,08	9,49	2,54	4,42	3,84	0,17	0,69
16,145	27,013	35,778	41,105	32,8	130	205	1,94	5452	2,99			42,12	30,74	9,4	2,57	4,4	3,78	0,17	0,69
15,943	25,283	36,115	40,308	33,2	135	210	2,05	5250	3,3			43,57	29,60	9,12	2,58	4,42	3,82	0,17	0,69
16,765	25,700	36,880	42,233	34	135	205	1,87	5353	2,4			42,5	31,17	9,57	2,61	4,42	3,69	0,17	0,69
15,470	25,350	36,443	42,293	34,2	140	215	2,17	5359	2,9			42,73	30,74	9,59	2,64	4,39	3,76	0,17	0,69
15,108	27,680	35,720	42,175	34,4	140	215	2,68	5097	3,13			40,31	31,54	9,65	2,62	4,61	3,79	0,17	0,70
15,675	28,515	35,850	40,975	34,6	145	220	3,6	5394	3,08			42,25	31,48	9,57	2,66	4,4	3,91	0,17	0,69
16,025	27,025	35,468	40,400	34,6	145	220	2,85	5316	3,05			41,94	31,89	9,79	2,67	4,41	3,84	0,17	0,69
15,300	25,703	36,823	41,225	34,8	150	225	2,9	5279	2,65			42,29	32,46	9,92	2,64	4,47	3,61	0,17	0,69
16,618	29,083	36,690	42,125	34,6	145	220	2,96	5225	2,9			42,93	32,50	9,79	2,64	4,46	3,74	0,17	0,69
15,183	27,070	35,958	40,800	34,6	140	215	2,74	5151	2,78			42,86	32,58	9,81	2,60	4,51	3,57	0,17	0,69
15,370	26,548	35,833	41,175	33,8	145	220	2,85	5103	3,07			43,05	32,06	9,66	2,60	4,47	3,74	0,17	0,69
15,345	27,768	36,960	41,700	34	135	210	3,42	4870	2,9			43,13	32,34	9,46	2,57	4,53	3,66	0,17	0,69
15,490	26,000	36,773	40,650	33,8	160	230	3,31	5082	2,64			43,24	31,89	9,68	2,54	4,42	3,75	0,17	0,69
17,018	32,173	38,075	42,000	33,8	140	215	3,19	4898	2,55			52,86	26,05	5,59	2,37	5,03	2,92	0,17	0,75
16,535	28,615	38,150	43,200	33,6	145	220	1,94	5374	2,98			43,27	31,50	9,9	2,54	4,39	3,74	0,17	0,69
15,600	26,435	36,800	41,300	34,2	150	225	2,28	5487	2,95			43,03	31,85	10,03	2,56	4,4	3,73	0,17	0,69

16,070	26,450	37,775	39,775	34,2	145	220	2,57	5553	3			42,67	32,03	10,13	2,57	4,41	3,78	0,17	0,69
14,688	26,225	36,925	41,900	34,4	145	220	3,59	5236	2,89			42,97	31,66	9,82	2,60	4,44	3,69	0,17	0,69
13,800	24,100	31,500	38,500	33	135	210	2,39	5374	3,34			40,45	31,22	9,4	2,54	4,74	4,12	0,17	0,70
13,150	22,225	30,700	38,898	33	120	200	2,79	5420	3,3			41,35	31,42	9,38	2,50	4,85	3,92	0,17	0,70
14,600	24,100	31,875	40,685	34	150	225	2,36	5136	2,95			41,04	31,82	9,59	2,49	4,96	3,80	0,17	0,70
12,100	24,700	34,250	39,700	34,4	150	225	2,51	5110	3,03			40,81	31,06	9,52	2,49	4,89	3,86	0,17	0,70
11,550	23,700	32,950	41,350	34,4	135	215	2,34	5002	2,94			41,73	31,24	9,42	2,55	4,59	3,77	0,17	0,70
11,600	25,425	34,100	41,975	34,2	145	225	1,76	5210	2,87			41,67	30,74	9,48	2,59	4,54	3,79	0,17	0,70
10,975	24,325	32,325	39,445	34,2	130	225	2,22	5034	2,85			44,36	30,95	9,1	2,65	4,32	3,77	0,17	0,69
12,903	25,583	35,325	40,285	34,6	140	215	2,62	5103	2,9			41,89	31,52	9,48	2,63	4,58	3,90	0,17	0,70
12,228	24,750	35,125	38,650	33,6	145	225	2,14	5320	2,92			42,6	30,69	9,09	2,63	4,44	3,96	0,17	0,71
12,625	23,800	30,675	37,428	33,6	125	205	2,79	5639	2,9			40,72	31,61	9,42	2,60	4,38	3,83	0,17	0,70
12,440	23,100	30,900	38,740	33,4	130	205	2,5	5083	2,87			42,12	32,04	9,43	2,55	4,27	3,82	0,17	0,70
12,800	25,075	31,848	38,035	34	135	210	2,73	5117	3,09			41,7	32,34	9,66	2,57	4,26	3,80	0,17	0,70
13,625	24,950	32,653	37,713	34	140	210	2,74	5009	2,76			42,88	31,63	9,29	2,58	4,32	3,83	0,17	0,70
13,700	25,420	33,258	39,943	33,4	130	205	2,74	5308	3,03			41,77	32,04	9,35	2,57	4,31	3,72	0,17	0,70
13,325	24,753	30,935	38,145	33,4	130	200	2,51	5450	2,74			42,04	32,57	9,48	2,57	4,29	3,78	0,17	0,70
12,315	24,378	31,950	40,438	34	140	210	2,57	5629	3			42,8	31,31	9,26	2,59	4,32	3,94	0,17	0,70
12,100	23,938	31,725	39,353	33,6	145	220	2,62	5174	3,08			41,83	31,87	9,56	2,62	4,15	3,85	0,17	0,70
11,415	24,525	34,900	40,548	33	145	220	2,91	5224	3,14			42,28	30,97	9,29	2,60	4,17	3,80	0,17	0,70
11,925	22,575	28,800	39,783	33	140	215	2,62	5306	2,7			42,05	32,43	9,71	2,59	4,11	3,69	0,17	0,70
12,725	23,345	33,240	39,060	32	135	210	3,08	4915	3,15			42,13	31,56	9,44	2,61	4,18	3,81	0,17	0,69
10,675	23,603	33,813	39,950	32	140	215	2,68	4865	3,46			44,2	30,28	8,92	2,61	4,25	4,04	0,17	0,69
13,758	24,303	32,235	41,575	32,4	140	210	3,07	4831	2,68			42,67	31,33	9,36	2,56	4,16	3,90	0,17	0,69
14,878	24,148	34,263	40,525	32,2	140	210	3,19	4870	3,18			41,7	32,44	9,42	2,53	4,24	3,82	0,17	0,70
14,375	24,380	32,273	41,400	32,4	200	210	3,07	4831	2,68			42	32,45	9,48	2,58	4,22	3,79	0,17	0,69
13,153	24,448	35,523	40,833	33	135	205	2,96	4776	3,04			41,34	31,84	9,55	2,59	4,17	3,88	0,17	0,70
10,118	24,788	34,553	40,565	33,4	155	225	3,19	5123	3,29			42,08	29,56	11,24	2,68	4,1	3,16	0,17	0,69
12,038	25,313	33,620	41,050	33,2	150	220	3,36	5124	3,26			41,87	28,06	11,32	2,74	3,98	3,69	0,17	0,69

13,293	25,150	34,325	40,750	33,4	140	210	3,36	5211	3,24			42,68	28,22	10,87	2,71	4,14	3,61	0,17	0,69
12,215	26,868	35,315	41,500	33,8	150	220	1,31	5740	3,6			40,85	29,44	10,89	2,66	4,24	3,72	0,17	0,69
15,350	27,443	36,003	41,975	34	145	215	1,94	5465	3,4			42,44	29,38	10,28	2,69	4,26	3,56	0,17	0,69
14,890	26,975	36,328	41,200	34	135	210	1,14	5744	3,4			43,1	28,94	9,97	2,70	4,25	3,69	0,17	0,70
14,235	25,988	35,975	42,050	33,8	140	215	2,52	5558	3,11			41,7	30,07	10,36	2,67	4,23	3,66	0,17	0,70
13,898	26,000	35,700	42,400	34,2	140	210	1,08	5446	3,78			42,84	29,63	9,83	2,69	4,33	3,67	0,17	0,70
14,175	25,425	34,575	41,310	34,4	160	230	1,24	6240	3,54			44,77	28,11	9,08	2,66	4,38	3,85	0,17	0,71
10,575	24,453	35,650	39,983	33	0	200	7,9	5998	2,42			42,61	28,96	10,64	2,70	4,31	3,58	0,17	0,70
13,983	25,050	36,000	43,650	33,4	140	230	1,48	5286	2,9			41,58	29,59	11,1	2,69	4,16	3,56	0,17	0,70
11,950	23,740	35,550	41,775	33	155	225	1,8	5770	3			41,92	29,18	11,02	2,69	4,14	3,51	0,17	0,70
13,275	24,525	34,925	40,925	33	130	215	1,67	5362	2,6			41,18	29,20	11,62	2,77	4,17	3,53	0,17	0,69
11,828	26,350	34,575	40,400	33,6	135	210	8,05	5072	2,5			40,77	29,18	11,74	2,76	4,13	3,58	0,17	0,69
14,500	26,050	35,965	42,125	34	145	220	1,19	6174	3,63			44,07	29,00	9,35	2,64	4,33	3,85	0,17	0,71
12,125	25,205	36,625	41,275	33	160	230	4,73	6125	3,32			43,57	28,70	9,97	2,67	4,39	3,60	0,17	0,71
10,775	24,850	34,075	41,458	33,6	160	245	7,55	5039	2,6			41,18	29,99	12,13	2,76	4,15	3,60	0,17	0,69
11,075	24,800	35,400	40,688	34	160	240	4,28	5079	2,32			51,6	23,70	5,58	2,69	4,77	3,45	0,17	0,73
12,325	24,125	33,850	40,928	33,6	135	210	6,9	5122	3,62			43,65	28,06	10,05	2,75	4,3	3,55	0,17	0,70
12,500	24,000	34,900	41,205	33,6	140	220	8,15	5481	2,51			40,77	29,66	11,68	2,77	4,1	3,74	0,17	0,69
12,800	23,075	35,130	40,775	35	140	220	4,48	5196	4,71			44,9	28,57	9,1	2,65	4,36	3,42	0,17	0,71
12,975	23,475	35,465	41,075	35	165	245	7,18	5159	4,04			60,88	18,74	4,64	3,02	4,69	4,04	0,17	0,71
12,620	25,008	31,275	40,575	35	160	260	6,05	4821	2,71			42,15	28,56	11,22	2,85	4,07	3,76	0,17	0,69
10,988	22,050	36,275	40,925	34,8	150	220	5,94	5474	2,8			42,18	28,58	11,07	2,80	4,13	3,73	0,17	0,69
11,385	23,750	34,375	38,675	34,4	150	220	5,88	5592	2,81			41,28	28,63	11,43	2,82	4,06	3,73	0,17	0,69
8,850	20,400	32,275	39,850	34,6	135	205	6,48	5530	2,67			41,26	28,67	11,71	2,85	4,04	3,85	0,17	0,69
11,500	23,400	33,870	40,943	35	180	255	4,85	5301	4,85			43,98	28,03	10,19	2,74	4,3	3,50	0,17	0,70
12,925	28,975	36,198	40,918	35,4	185	285	1,69	5519	3,64			43,15	28,46	10,64	2,77	4,2	3,64	0,17	0,70
14,525	25,835	35,335	41,455	35,4	170	240	3,54	5767	4,01			43,45	28,61	10,45	2,75	4,24	3,51	0,17	0,70
11,768	25,075	35,050	40,150	36	145	220	4,5	6003	3,05			40,59	29,53	12,1	2,82	3,98	3,61	0,17	0,69
10,465	22,450	33,075	40,050	36	145	220	3,9	5594	2,95			40,43	29,58	12,01	2,82	4	3,84	0,17	0,69

10,000	23,003	32,950	39,400	34,4	175	290	5,6	5596	3,17			41,03	29,31	11,33	2,70	4,12	3,69	0,17	0,69
10,625	23,075	32,325	38,625	34,8	145	220	4,74	5839	3			38,44	30,32	12,1	2,69	3,95	3,91	0,17	0,69
10,670	20,525	28,550	39,000	35,4	145	225	4,14	5727	2,9			40,79	28,76	11,52	2,77	3,98	4,00	0,17	0,69
9,675	25,875	34,790	40,410	36	150	220	3,92	6232	2,99			39,57	29,73	11,79	2,71	3,97	4,01	0,17	0,69
12,025	25,700	34,790	41,168	36,4	135	250	3,71	6279	3,23			39,25	30,19	11,76	2,73	3,95	4,20	0,17	0,69
13,935	28,750	40,425	42,203	34,8	140	215	5,12	5948	3,14			43,05	28,23	11	2,79	3,96	3,83	0,17	0,70
14,463	26,913	36,050	42,103	35	130	205	5,07	5975	3,34			40,45	29,50	11,72	2,72	3,94	3,85	0,17	0,70
15,500	27,278	34,575	41,610	35,2	123	200	3,8	6423	3,06			42,03	28,50	11,35	2,82	3,92	3,92	0,17	0,69
11,500	25,478	35,425	42,240	35,2	120	190	4,9	6065	3,14			41,15	28,85	11,72	2,80	3,89	3,98	0,17	0,69
16,235	24,990	36,925	43,525	35,2	110	190	5,18	6279	3,34			40,71	29,22	11,83	2,75	3,88	3,85	0,17	0,69
10,825	24,850	34,050	42,945	35	130	205	5,7	5448	3,08			41,3	28,72	11,89	2,80	3,95	3,94	0,17	0,69
11,838	25,825	35,625	41,248	35,4	130	200	5,94	7020	3,32			40,43	29,82	11,85	2,79	4,02	3,67	0,17	0,69
13,153	26,563	39,188	42,725	35	145	235	3,52	6195	3,52			60,43	19,47	5,02	2,91	4,79	3,98	0,17	0,72
15,400	28,325	35,698	41,225	35,6	120	195	4,36	5561	2,58			42,65	28,55	10,59	2,77	4,09	3,77	0,17	0,70
16,725	28,243	37,633	44,233	35,6	130	205	3,4	5868	2,52			44,15	28,65	10,07	2,75	4,16	3,81	0,17	0,71
13,208	27,568	34,938	40,975	35,6	120	195	2,34	5519	2,46			45,82	27,73	9,76	2,76	4,2	3,92	0,17	0,71
14,703	25,888	36,165	39,425	35,8	130	205	3,6	5976	2,56			41,15	29,14	11,18	2,74	4,04	3,93	0,17	0,70
16,083	31,558	38,390	43,100	36	125	200	3,54	6142	3,11			41,01	29,31	11,41	2,77	4,07	3,88	0,17	0,70
15,458	26,113	35,170	40,250	34,2	130	210	4,8	5840	3,18			41,78	29,06	10,8	2,74	4,32	3,83	0,17	0,70
14,368	25,270	33,913	41,095	34,6	135	220	5,29	6082	2,93			40,71	29,73	10,92	2,71	4,33	3,81	0,17	0,70
13,693	26,713	35,753	40,308	34,8	135	210	5,23	6083	2,75			41,18	29,82	11,04	2,72	4,3	3,78	0,17	0,70
15,888	26,560	38,778	43,713	34,8	125	210	5,45	6073	2,94			41,6	29,54	10,89	2,73	4,32	3,82	0,17	0,70
14,255	25,388	38,355	40,455	35,2	120	225	4,8	6179	2,98			40,33	29,71	11,46	2,72	4,32	3,80	0,17	0,70
13,360	26,725	35,625	43,990	34,4	140	220	4,74	5836	3,3			41,54	28,78	11,08	2,77	4,11	3,87	0,17	0,70
13,875	26,223	37,475	40,935	34,4	115	210	4,37	6059	3,04			42,18	28,66	10,92	2,75	4,15	3,87	0,17	0,70
12,775	29,875	38,400	41,705	35,2	120	205	3,24	5998	3,55			42,79	28,20	10,35	2,74	4,18	3,84	0,17	0,70
12,625	24,905	37,000	40,878	35	120	240	5,01	5843	2,97			41,03	29,66	11,19	2,71	4,21	3,75	0,17	0,70
12,500	28,850	35,920	42,643	34,2	135	215	4,37	5687	3,76			41,09	28,88	11,2	2,72	4,14	3,89	0,17	0,69
13,310	29,265	36,555	42,300	34,6	135	220	4,25	5705	3,44			41,11	28,91	11,42	2,75	4,03	3,83	0,17	0,69

13,623	30,120	38,275	45,025	35	135	220	4,08	5948	3,63			41,46	28,70	11,03	2,74	4,04	3,88	0,17	0,69
13,488	26,930	36,900	41,618	34,8	130	210	4,47	5859	3,97			41,02	28,95	11,48	2,75	4,01	3,84	0,17	0,69
13,515	27,635	36,020	41,853	34,8	135	220	4,14	6023	3,71			41,75	29,04	11,2	2,75	4,05	3,88	0,17	0,69
15,435	28,445	38,450	43,005	35	140	215	3,19	6265	3,86			41,5	29,29	11,43	2,77	4,14	3,91	0,17	0,69
13,153	26,563	39,188	42,725	35	145	235	3,52	6195	3,52			41,85	28,82	11,11	2,78	4,12	3,93	0,17	0,69
13,415	27,305	37,485	42,033	35	140	220	4,8	6240	3,02			39,99	29,63	11,62	2,70	4,14	3,81	0,17	0,69
13,590	26,048	36,303	41,235	35,4	130	210	4,21	5643	3,24			41,52	29,29	11,02	2,70	4,27	3,82	0,17	0,70
12,825	23,725	35,438	41,128	35,4	130	215	4,25	6222	3,57			39,39	29,64	11,7	2,70	4,16	3,94	0,17	0,69
10,615	22,945	35,195	45,625	33,6	140	220	6,7	5731	2,81			42,41	29,34	10,51	2,68	4,44	3,76	0,17	0,69
12,700	26,243	36,975	43,738	34,2	135	220	5,67	6384	2,74			40,91	29,73	10,77	2,66	4,41	3,77	0,17	0,70
12,430	24,950	35,780	43,803	34,6	130	205	6,43	6046	2,8			42,49	31,56	10,87	2,64	4,6	3,70	0,17	0,70
12,033	24,480	34,243	42,125	34,6	135	220	6,81	6069	2,61			40,92	29,81	10,73	2,66	4,35	3,73	0,17	0,70
12,203	23,973	34,550	41,005	34,6	135	210	6,27	6102	2,69			41,23	30,36	10,85	2,69	4,39	3,87	0,17	0,69
11,450	23,345	35,790	42,855	34,8	130	205	4,74	6419	2,74			51,14	26,04	5,49	2,46	5,16	2,88	0,17	0,75
11,748	24,513	35,230	41,310	35	135	215	5,29	6223	2,94			41,26	29,44	11,04	2,73	4,3	3,86	0,17	0,70
10,375	23,810	35,505	45,120	35,4	125	200	6,21	5938	2,63			40,86	29,47	11,42	2,76	4,17	3,84	0,17	0,69
13,338	26,053	36,830	42,325	35	135	210	5,51	5947	3,09			39,67	29,75	10,65	2,63	4,88	3,93	0,17	0,70
13,863	24,100	36,945	44,075	35	135	210	4,47	5960	2,73			39,7	29,94	10,64	2,67	4,97	3,88	0,17	0,70
13,680	23,950	36,103	40,275	35,2	135	210	6,49	6017	3,27			41,05	28,58	10,07	2,69	4,98	3,85	0,17	0,70
13,280	24,950	36,478	40,583	34,5	125	200	7,74	5772	2,9			40,88	29,41	10,55	2,67	4,73	3,81	0,17	0,70
13,670	28,463	35,333	40,350	34,7	150	225	8,64	5816	2,91			40,6	29,55	10,81	2,69	4,51	3,68	0,17	0,70
13,228	27,575	36,823	42,525	33,8	135	220	6,1	6229	3,51			41,86	28,97	10,05	2,66	4,45	3,77	0,17	0,70
10,675	29,733	36,913	42,350	34	140	215	5,72	6183	3,59			42,09	29,81	10,33	2,64	4,44	3,78	0,17	0,70
14,865	26,935	38,045	44,375	34	135	220	5,67	6024	3,5			42,18	29,57	10,27	2,64	4,48	3,79	0,17	0,70
12,425	26,715	36,525	43,063	33,8	135	210	8,39	5549	3,22			41,6	30,00	10,42	2,62	4,44	3,74	0,17	0,70
13,143	27,013	35,543	41,855	34	145	220	8,18	5611	3,3			41,58	30,17	10,45	2,63	4,46	3,68	0,17	0,70
12,483	27,180	37,418	41,125	34,2	155	230	5,61	5808	3,28			41,32	30,01	10,47	2,63	4,42	3,86	0,17	0,70
13,335	24,945	33,950	40,233	34	135	200	5,45	5403	3			39,7	31,84	10,63	2,50	4,35	3,94	0,17	0,70
12,915	24,638	33,475	40,853	33,8	135	210	7,36	5409	3,04			41,49	30,18	10,1	2,56	4,38	3,98	0,17	0,70

11,298	24,683	33,538	40,188	33,6	130	200	7,14	5424	3,29			41,64	30,44	10,28	2,57	4,4	3,98	0,17	0,70
11,625	24,225	32,388	40,325	33	105	235	7,03	5579	4,28			41,63	29,41	10,39	2,71	4,05	3,83	0,17	0,70
11,823	24,445	34,188	40,665	32,4	140	215	6,81	6005	4,33			39,72	30,79	10,35	2,51	4,41	3,82	0,17	0,71
11,400	24,975	31,550	41,513	30,5	110	210	7,52	5950	4,53			41,7	29,21	9,84	2,59	3,92	4,10	0,17	0,71
11,250	24,160	30,175	41,195	30,6	106	276	7,63	5297	5,22			40,12	28,80	9,9	2,57	3,94	3,79	0,17	0,70
11,413	23,163	29,925	39,620	29,5	110	225	6,27	5590	5,19			42,27	29,75	9,85	2,54	4,11	3,86	0,17	0,70
11,263	23,900	32,663	41,478	29,5	115	235	5,9	5590	5,37			41,43	29,58	9,98	2,53	4,04	4,64	0,17	0,70
10,450	22,378	31,338	37,600	29,5	120	225	6,54	5642	5,32			41,21	30,19	10,22	2,54	4,03	3,76	0,17	0,70
9,710	21,798	30,223	39,410	29,3	120	200	6,05	5573	5,31			40,39	29,59	10,28	2,54	4	3,79	0,17	0,70
10,225	22,650	32,950	37,885	29,5	80	180	5,78	5488	5,31			40,8	29,98	10,27	2,53	4,04	3,79	0,17	0,70
9,538	21,100	31,925	37,440	29,5	145	255	6,05	5549	5,33			40,51	30,03	10,46	2,55	4,02	3,86	0,17	0,70
8,660	21,900	30,358	37,758	29,5	125	310	5,67	5629	5,18			41,14	29,47	10,23	2,56	3,99	3,91	0,17	0,70
10,660	22,250	31,338	37,475	28,9	70	290	5,01	6102	5,07			40,06	30,12	10,61	2,54	3,96	3,98	0,17	0,70
8,925	22,208	31,633	37,963	29,6	95	245	6,75	5634	5,16			40,28	30,30	10,52	2,53	4,02	3,87	0,17	0,70
11,775	21,523	32,535	39,840	28,8	65	215	5,01	6037	4,88			40,67	30,30	10,49	2,55	4,07	3,88	0,17	0,70
14,610	23,268	35,393	40,778	29,8	90	220	4,58	6113	4,55			42,85	29,29	9,85	2,61	4,22	4,00	0,17	0,71
11,503	21,565	30,898	40,108	29,7	55	185	5,4	6340	4,82			42,2	29,13	10,19	2,60	4,19	4,12	0,17	0,71
15,878	26,708	35,813	40,713	29,8	105	210	3,05	5727	4,81			47,42	26,23	8,26	2,65	4,67	3,90	0,17	0,71
10,465	24,698	35,048	41,118	29,6	60	175	7,68	6811	5,28			40,5	29,92	10,74	2,62	4,14	3,75	0,17	0,71
11,370	22,153	33,735	39,848	29,4	60	245	7,36	6438	5,21			41,37	29,74	10,5	2,60	4,13	3,77	0,17	0,70
12,460	22,030	33,540	41,200	29,6	70	235	8,88	6515	5,33			41	29,53	10,6	2,61	4,14	3,72	0,17	0,71
14,088	28,038	36,065	42,190	29,4	61	225	5,12	6805	5,43			40,19	29,80	10,75	2,62	4,09	3,90	0,17	0,71
10,303	24,905	34,728	40,693	29,4	63	240	7,19	6413	5,14			40,86	29,42	10,42	2,60	4,27	3,90	0,17	0,71
17,833	22,203	34,493	40,668	29,4	64	230	10,63	6180	5,33			39,47	29,68	10,64	2,55	4,48	3,79	0,17	0,71
12,400	22,035	35,205	41,100	29,6	65	190	6,38	6350	5,11			39,98	30,04	10,51	2,57	4,28	4,13	0,17	0,71
10,500	22,280	34,825	39,003	29	66	195	9,37	6200	5,4			39,78	29,28	10,45	2,57	4,4	4,06	0,17	0,71
11,415	24,708	35,570	42,230	29,6	67	215	6,65	6012	5,28			39,82	29,41	10,55	2,58	4,43	3,77	0,17	0,71
11,395	24,428	36,000	41,675	31,6	68	225	6,32	6478	5,35			39,65	30,02	10,89	2,57	4,22	3,85	0,17	0,71
12,835	25,310	36,023	41,920	31,4	100	220	5,83	6409	5,06			40	30,42	10,68	2,56	4,01	3,76	0,17	0,71

12,420	24,370	35,338	40,425	31,4	100	220	7,09	6228	4,7			40,39	30,88	10,65	2,54	4,06	3,70	0,17	0,70
13,573	26,325	35,913	41,750	31,2	155	255	4,91	6408	4,77			42,24	28,30	9,7	2,59	4,28	3,96	0,17	0,71
12,493	25,810	34,460	40,560	32,3	120	215	6,43	6194	3,98			39,1	31,33	10,71	2,53	4,29	3,63	0,17	0,70
11,765	25,690	35,510	42,073	32	115	210	4,96	6054	4,29			40,1	30,57	10,47	2,53	4,28	3,73	0,17	0,71
11,228	23,708	34,598	39,773	31	145	235	7,85	5700	4,29			42,16	29,27	9,94	2,57	4,39	3,80	0,17	0,71
10,570	25,205	34,578	40,083	31,6	155	235	4,96	5564	4,29			41,13	29,48	10,27	2,57	4,43	3,83	0,17	0,71
16,465	30,125	37,620	43,403	32,6	135	190	5	5560	3,5			43,18	28,20	9,94	2,54	4,52	3,80	0,17	0,71
13,730	29,065	37,500	43,098	32,4	130	210	5,34	5949	3,91			41,9	29,33	10,39	2,53	4,52	3,70	0,17	0,70
13,620	27,535	37,878	42,310	32,6	135	220	6,05	6055	4,29			41,52	29,19	10,41	2,53	4,44	3,94	0,17	0,70
13,813	28,393	35,938	41,280	32,8	120	230	7,36	6166	4,5			39,76	30,23	11,07	2,50	4,38	3,78	0,17	0,70
13,305	25,765	38,030	42,620	32,8	125	210	6,7	6311	4,52			39,27	30,61	10,71	2,49	4,39	3,76	0,17	0,70
14,098	28,165	36,525	43,373	32,4	125	215	7,68	5999	3,96			40,94	29,11	10,56	2,55	4,34	3,89	0,17	0,70
14,718	30,133	36,865	40,710	33	135	215	7,9	5838	3,32			40,31	29,50	11,3	2,43	4,37	3,68	0,17	0,70
16,540	29,790	36,410	42,845	33,2	120	200	7,95	5797	3,12			40,37	28,81	11	2,47	4,38	3,60	0,17	0,70
15,328	29,798	35,765	42,773	33	125	205	6,7	6336	4,01			38,84	30,29	11,47	2,44	4,4	3,65	0,17	0,70
16,438	32,208	38,138	44,743	32,6	115	206	7,3	6150	4,112			38,81	30,19	11,37	2,45	4,41	3,76	0,17	0,70
15,238	29,635	36,980	40,853	32,8	110	190	7,14	6286	3,6			39,09	30,32	11,33	2,44	4,44	3,68	0,17	0,70
16,280	30,190	37,848	41,498	32,8	110	190	4,85	6664	3,11			39,89	31,99	11,55	2,41	4,6	3,94	0,17	0,70
14,293	27,955	35,708	43,518	33	120	200	5,8	6362	4,85			40,44	31,85	11,43	2,44	4,57	3,77	0,17	0,70
17,073	29,768	37,430	43,338	32,9	115	240	5,2	6183	4,45			41,99	31,37	11,01	2,46	4,56	3,80	0,17	0,70
13,278	28,238	35,920	41,063	33,4	100	230	5,21	6321	5,72			39,29	30,90	11,46	2,43	4,53	3,74	0,17	0,70
12,460	27,403	38,995	44,080	34,1	135	240	4,91	5876	4,04			40,05	29,58	11,21	2,44	4,29	3,84	0,17	0,69
14,718	30,255	38,205	42,198	33,8	120	265	2,15	5849	3,62			41,33	32,02	11,81	2,39	4,5	4,18	0,17	0,70
13,455	27,683	38,115	44,440	33,5	130	230	4,52	5807	3,49			40,18	30,33	11,51	2,43	4,29	3,69	0,17	0,70
13,108	27,308	36,845	43,768	33,5	150	250	4,74	5592	3,5			40,14	29,85	11,44	2,43	4,26	3,71	0,17	0,70
13,228	26,575	38,255	43,843	33,6	120	210	3,82	6286	3,92			40,7	29,25	11,08	2,46	4,21	3,76	0,17	0,70
13,463	30,903	36,155	46,040	33,3	120	220	4,36	6600	4,04			39,93	29,80	11,3	2,47	4,16	3,82	0,17	0,70
16,035	30,870	35,468	44,348	33,8	110	225	2,78	6814	4,11			40,38	29,43	11,12	2,56	4,2	4,06	0,17	0,71
13,718	30,480	37,033	44,580	33,8	100	215	3,05	7488	3,92			38,59	30,72	11,79	2,49	4,15	3,94	0,17	0,71

13,023	30,638	38,538	42,945	33,8	90	170	2,67	7240	4,15			40,26	30,35	11,52	2,54	4,21	3,94	0,17	0,71
14,080	28,553	37,550	43,468	34	120	215	3,71	6918	4,1			39,51	29,82	11,35	2,53	4,15	3,82	0,17	0,70
14,288	29,110	38,275	45,203	33,4	140	240	3,11	5999	3,91			41,63	29,23	10,82	2,58	4,32	3,46	0,17	0,70
16,115	30,125	37,790	44,918	33,4	85	220	4,36	7201	3,29			41,2	29,07	10,82	2,62	4,27	3,76	0,17	0,71
16,105	30,050	36,828	43,655	33,4	105	200	5,34	7167	3,2			41,7	28,84	10,48	2,54	4,34	3,85	0,17	0,71
14,183	28,293	37,715	45,120	34	110	215	4,8	6909	3,38			41,2	28,75	10,54	2,52	4,41	3,74	0,17	0,71
12,918	26,963	38,623	42,978	34	110	190	4,96	6690	3,09			41,31	29,33	10,78	2,51	4,4	3,79	0,17	0,71
15,058	27,055	38,393	41,520	34	105	195	5,56	6778	3,77			40,46	29,79	10,8	2,53	4,51	3,75	0,17	0,70
14,115	29,535	37,665	43,725	34,4	135	215	5,07	6464	3,2			41,87	28,72	10,37	2,57	4,63	3,96	0,17	0,70
15,803	30,050	37,973	45,075	34,4	120	210	3,05	6673	3,07			41,51	29,18	10,78	2,54	4,6	3,95	0,17	0,70
16,963	30,150	39,588	45,510	34,4	115	205	3,32	6263	2,92			42,09	28,92	10,5	2,56	4,64	3,71	0,17	0,70
16,420	28,958	40,460	43,923	34,4	110	195	2,89	6236	3,12			42,67	29,01	10,44	2,56	4,66	3,65	0,17	0,70
16,688	29,473	39,880	44,250	35	110	190	3,05	6711	2,97			40,06	29,50	11,21	2,56	4,42	3,97	0,17	0,70
16,303	28,948	37,855	43,695	34,2	110	200	3,32	6608	3,56			39,83	30,64	11,05	2,56	4,24	3,90	0,17	0,71
15,450	28,720	35,895	43,833	34,4	120	215	4,2	6288	3,41			42,54	30,88	10,46	2,55	4,47	3,75	0,17	0,71
14,840	27,923	37,848	40,753	34,2	135	215	4,52	6053	3,42			42,91	28,78	9,79	2,55	4,5	3,79	0,17	0,71
13,853	28,613	37,608	43,005	34,2	105	185	4,96	6620	3,65			41,97	29,54	10,26	2,58	4,47	3,77	0,17	0,71
14,923	29,278	38,258	44,068	34,6	110	200	4,31	6794	3,33			40,2	29,19	10,29	2,60	4,32	3,85	0,17	0,71
16,275	31,438	38,843	44,048	35	140	245	4,3	6507	3,52			40,49	30,14	10,51	2,63	4,35	4,23	0,17	0,71
16,095	30,305	39,970	45,028	35	130	220	3,25	6498	3,25			40,03	29,47	10,5	2,64	4,23	4,12	0,17	0,71
12,885	25,488	35,888	41,470	34,4	150	225	7,8	5328	3,48			42,45	29,04	10,17	2,60	4,5	3,20	0,17	0,71
12,535	26,413	35,223	42,838	34,4	150	220	7,83	6243	3,59			43,9	27,45	9,49	2,66	4,51	3,39	0,17	0,71
14,233	25,308	38,863	42,890	34,2	125	210	5,2	7348	3,41			39,54	30,05	11,38	2,58	4,27	3,85	0,17	0,70
13,920	27,328	37,645	43,528	34,2	120	205	5,74	6700	3,45			40,05	29,21	10,7	2,60	4,34	3,56	0,17	0,70
13,923	28,108	37,048	43,340	29,2	135	210	7,05	6730	3,77			41,15	29,14	10,29	2,63	4,43	3,61	0,17	0,71
15,000	26,858	37,200	44,353	34,2	120	210	6,75	6511	4,17			41,5	30,46	10,32	2,60	4,48	3,94	0,17	0,71
14,425	26,820	37,460	44,303	33,4	130	210	5,17	6669	4,56			41,82	28,55	9,49	2,67	4,58	3,94	0,17	0,70
14,733	28,003	38,148	42,230	33	130	210	5,1	6718	4,61			42,16	28,41	9,57	2,70	4,59	3,86	0,17	0,70
13,593	27,033	38,233	41,388	33	120	225	5,2	6947	4,03			40,88	28,10	9,72	2,73	4,57	3,66	0,17	0,70

13,763	27,870	36,288	40,943	33	130	225	6,15	7034	4,29			41,1	28,61	9,82	2,72	4,58	3,76	0,17	0,70
13,743	27,663	36,875	41,058	33,6	130	225	5,65	6367	4,6			41,62	28,92	9,87	2,65	4,63	3,45	0,17	0,70
13,708	27,153	36,288	41,163	33,2	125	220	6,8	6646	4,15			41,71	28,92	9,72	2,65	4,65	3,41	0,17	0,70
15,018	27,020	38,640	42,728	33,4	135	215	7,01	6754	4,39			41,11	28,39	9,73	2,70	4,55	3,78	0,17	0,70
14,788	27,133	38,090	43,290	33,2	150	225	6,87	6825	4,21			40,76	27,86	9,55	2,69	4,51	3,68	0,17	0,70
14,418	27,415	35,815	41,528	33,4	140	220	7,1	6627	4,11			42,08	28,69	9,77	2,67	4,54	3,66	0,17	0,70
12,198	27,345	35,565	43,260	33,4	140	220	6,93	6380	4,18			41	28,41	9,72	2,69	4,52	3,62	0,17	0,70
12,123	28,565	37,645	44,513	33,4	125	205	6,8	6307	3,67			42,29	29,55	9,7	2,70	4,35	3,72	0,17	0,70
13,555	28,735	37,920	44,603	33,8	140	220	4,7	6436	2,98			51,65	23,34	5,48	2,75	4,89	3,57	0,17	0,72
15,298	28,195	35,770	44,403	33,6	140	220	6,2	6471	3,61			42,66	29,29	9,49	2,73	4,41	3,92	0,17	0,70
17,315	29,635	36,275	43,258	33,6	145	215	4,3	6538	2,76			42,17	29,33	9,27	2,81	4,24	4,28	0,17	0,69
13,325	26,338	38,383	43,725	33,8	140	230	6,02	6066	2,77			43,24	29,29	9,03	2,82	4,28	4,04	0,17	0,69
12,873	25,660	38,518	43,278	33,8	130	210	8	5912	2,89			40,28	30,80	10,06	2,70	4,23	3,67	0,17	0,69
13,045	27,600	35,905	42,873	33,2	150	230	6,91	6247	3,62			41,06	28,57	9,67	2,63	4,17	4,07	0,17	0,71
13,428	28,733	36,000	41,768	32,4	140	220	4,31	6480	3,61			40,44	28,89	9,8	2,62	4,13	3,90	0,17	0,71
14,785	29,223	37,968	44,013	32,6	130	220	4,57	6607	3,43			41,19	29,00	10,03	2,65	4,13	4,20	0,17	0,70
13,300	26,810	38,318	43,060	32,8	135	215	4,91	6736	3,43			42,84	28,78	9,07	2,64	4,31	3,74	0,17	0,70
15,088	26,948	37,640	42,238	33,4	135	235	4,1	6231	3,39			41,29	30,62	9,98	2,62	4,2	3,91	0,17	0,70
13,295	26,615	37,753	43,253	33,4	150	210	6,9	6331	3,23			41,9	29,92	9,47	2,66	4,2	3,92	0,17	0,70
14,445	27,185	34,443	43,940	33,4	135	240	7,1	6280	3,25			41,89	30,62	9,72	2,64	4,24	3,94	0,17	0,70
13,500	27,370	36,375	43,755	33,8	135	215	7,445	6150	3,86			42,19	29,16	9,82	2,60	4,42	3,84	0,17	0,71
13,253	28,243	36,700	42,735	34	135	220	5,01	6131	3,11			41,09	30,95	9,8	2,63	4,28	4,09	0,17	0,70
13,443	26,713	37,490	42,788	34	135	220	5,12	6284	3,22			41,56	30,54	9,63	2,64	4,25	3,94	0,17	0,70
13,338	24,930	36,993	43,350	34	130	220	5,15	6370	3,32			42,93	29,91	9,18	2,64	4,32	3,94	0,17	0,70
13,420	28,100	36,185	41,938	34	135	225	5,61	6320	3,56			41,56	28,97	10,36	2,61	4,38	3,82	0,17	0,70
13,115	26,375	36,198	43,515	34,4	135	235	5,55	6573	3,66			40,72	29,24	10,13	2,81	4,24	3,68	0,17	0,70
13,065	25,598	38,610	43,363	34,4	135	245	6,5	6387	3,68			39,96	30,21	10,52	2,81	4,17	4,14	0,17	0,70
12,420	25,743	37,108	42,253	33,4	135	250	5,4	6490	3,52			41,37	29,89	10,11	2,79	4,18	4,16	0,17	0,70
12,535	25,458	36,583	43,928	33,6	135	235	3,8	6180	3,17			40,5	30,30	10,13	2,80	4,12	4,27	0,17	0,70

12,615	25,410	35,958	40,978	33,8	135	240	3,9	6020	3,38			41,49	30,41	9,79	2,80	4,21	3,89	0,17	0,70
13,388	26,028	37,378	43,105	33,6	135	230	3,75	5995	3,21			41,89	29,94	9,6	2,79	4,21	3,94	0,17	0,70
12,185	25,110	36,975	42,965	33,4	135	220	5,28	6230	3,34			42,37	29,13	9,41	2,77	4,24	3,91	0,17	0,70
11,625	24,765	36,585	43,150	33,4	135	225	5,5	6059	3,29			42,82	29,20	9,38	2,78	4,23	3,90	0,17	0,70
11,415	24,473	36,998	42,665	33,6	130	220	5,66	6218	3,46			41,84	29,43	9,55	2,78	4,23	3,74	0,17	0,70
12,623	26,145	35,673	44,245	33,6	135	225	5,61	7200	3,46			43	29,63	9,54	2,79	4,24	3,92	0,17	0,70
12,440	26,948	36,093	40,403	33	140	230	4,9	6120	3,98			42,99	31,20	9,7	2,83	4,16	3,78	0,17	0,69
13,995	26,343	37,978	41,828	32,4	140	230	5,1	6080	4,11			42,28	30,00	9,42	2,84	4,12	3,75	0,17	0,71
12,905	26,960	36,843	42,183	32	135	230	5,6	5930	4,22			44,57	29,02	8,94	2,82	4,19	3,93	0,17	0,71
12,313	26,638	36,498	41,618	32	135	230	5,3	5840	4,39			44,37	28,45	8,86	2,83	4,18	3,60	0,17	0,71
12,115	25,945	35,580	41,660	31,4	140	210	4,7	5690	4,34			44,17	29,34	8,78	2,90	4,33	3,61	0,17	0,71
11,728	27,455	36,438	42,283	31	130	220	4,6	5483	4,01			44,84	29,60	8,81	2,88	4,23	3,57	0,17	0,71
8,563	24,638	35,225	41,343	31	140	230	4,3	5585	4,19			45,22	30,52	8,84	2,90	4,26	3,61	0,17	0,71
11,330	26,603	36,255	40,695	31,6	150	230	4,2	5397	4,11			44,67	30,83	9,11	2,85	4,26	3,72	0,17	0,70
12,520	26,320	36,175	45,568	34,4	150	230	4,05	6040	3,31			42,85	30,67	9,8	2,77	4,25	4,06	0,17	0,70
11,633	25,508	36,460	42,990	32,6	130	225	4,2	5232	3,75			43,3	30,98	9,55	2,83	4,27	3,95	0,17	0,70
14,335	24,740	34,348	42,053	32,8	135	240	4,1	5726	3,59			43,78	30,58	9,73	2,82	4,25	3,91	0,17	0,70
13,218	26,905	37,435	43,375	33,4	135	230	5,36	5777	3,69			42,68	29,25	9,77	2,81	4,17	4,02	0,17	0,70
13,185	25,998	38,070	44,160	33,4	130	225	6,1	5377	3,72			44,45	29,43	9,42	2,79	4,23	3,72	0,17	0,70
12,623	26,225	38,563	41,268	33,2	140	225	5,4	5336	3,87			43,18	30,38	9,47	2,82	4,22	3,66	0,17	0,70
12,360	25,850	35,540	43,840	33,4	135	225	4,6	5511	3,79			43,14	30,23	9,5	2,79	4,24	4,03	0,17	0,70
12,343	25,563	38,193	43,008	33,4	135	220	4,5	5714	4,12			44,09	29,35	9,25	2,79	4,24	3,96	0,17	0,70
12,580	26,100	38,810	44,060	33,6	130	220	4,83	5520	3,9			42,93	30,83	9,63	2,80	4,23	3,89	0,17	0,70
12,700	26,520	38,500	44,780	33,4	140	240	4,11	5578	3,69			42,72	29,48	9,85	2,79	4,14	4,52	0,17	0,70
12,280	26,330	37,010	43,330	33,6	130	220	4,54	5637	3,84			43,07	31,30	9,78	2,80	4,25	3,93	0,17	0,70
12,520	27,520	37,220	43,430	33,5	135	220	4,6	5551	4,35			45,59	28,05	8,99	2,80	4,23	4,06	0,17	0,70
12,100	29,180	37,030	44,730	33,4	130	220	4,76	5532	4,63			46,61	28,64	8,99	2,81	4,24	4,26	0,17	0,70
11,390	30,170	36,240	43,480	33	140	230	4,74	5747	5			45,49	27,29	8,93	2,81	4,12	4,34	0,17	0,69
12,660	30,370	35,940	44,340	32	135	235	4,7	5674	4,48			45,81	27,36	8,99	2,83	4,19	4,32	0,17	0,70

13,030	30,800	36,810	43,810	32,2	140	245	4,68	5850	4,35			43,31	28,75	9,2	2,86	4,22	3,50	0,17	0,70
13,115	28,818	37,415	43,603	32,2	130	225	4,57	5720	4,55			44,84	29,09	9,27	2,85	4,3	3,58	0,17	0,70
13,918	27,298	36,515	44,370	31,2	135	240	4,4	5790	4,24			44,07	30,13	9,6	2,84	4,29	3,39	0,17	0,70
12,923	27,703	36,460	44,543	31,4	145	240	4,1	5744	4,13			42,63	30,32	9,87	2,86	4,24	3,75	0,17	0,70
13,050	26,615	36,060	45,265	31,4	135	220	4,3	5810	4,45			43,14	29,83	9,76	2,85	4,23	3,55	0,17	0,70
13,108	27,673	36,625	44,093	31,4	160	230	4,1	6400	3,76			43,95	29,18	9,78	2,82	4,12	3,83	0,17	0,70
12,230	27,070	38,760	44,760	33,4	135	225	4,2	5562	3,8			42,05	30,45	10,4	2,88	4,18	3,91	0,17	0,71
9,028	23,715	37,218	43,808	31,6	120	200	3,54	6027	4,78			44,94	29,05	9,24	2,83	4,19	3,96	0,17	0,70
10,475	27,085	36,603	41,750	31,2	145	200	2,25	6089	5,26			44,16	29,69	9,37	2,87	4,15	3,96	0,17	0,70
12,323	27,415	36,175	41,833	32	175	235	3,1	5870	4,9			43,86	30,12	9,64	2,85	4,19	3,81	0,17	0,70
12,675	27,428	37,188	42,738	31,6	150	240	4,1	5877	4,5			43,32	30,51	9,79	2,87	4,24	3,44	0,17	0,70
12,763	29,795	37,130	43,313	31,7	145	245	4,15	6718	4,39			44,05	29,46	9,68	2,87	4,24	3,76	0,17	0,70
11,633	28,030	37,510	42,608	31,2	115	210	4,52	6513	4,52			61,89	19,46	6,55	2,80	4,44	3,68	0,17	0,71
12,735	27,363	37,218	43,075	30,7	125	230	4,51	6612	4,23			43,27	30,28	9,65	2,93	4,27	3,42	0,17	0,70
13,065	27,553	37,473	41,783	31,6	160	250	4,3	6280	4,64			42,55	29,96	9,96	2,95	4,14	3,84	0,17	0,70
13,268	30,105	39,128	42,985	31,7	145	230	6,8	6795	4,65			42,35	30,16	9,87	2,90	4,2	3,74	0,17	0,70
13,383	28,425	38,645	42,405	32	135	220	4	6481	3,17			45,97	29,39	8,01	3,19	4,65	1,69	0,17	0,74
13,433	28,123	37,885	43,058	32	135	215	5,13	6637	5			42,68	30,67	10,01	2,91	4,17	3,88	0,17	0,70
12,618	32,915	37,910	42,523	31,8	135	215	4,7	6666	4,47			40,63	29,90	10,54	2,91	4,15	4,08	0,17	0,70
12,310	31,680	37,028	42,503	32,6	145	215	3,85	6570	4,44			40,28	30,00	10,75	2,90	4,15	4,13	0,17	0,70
12,185	27,893	38,953	42,568	32,04	140	220	3,5	6745	4,34			40,19	29,38	10,38	2,79	4,07	4,46	0,17	0,69
11,398	28,343	38,725	41,718	31,4	155	230	6,5	6623	4,8			42,96	28,82	9,91	2,83	4,09	4,40	0,17	0,70
12,603	27,413	36,965	40,835	31,4	140	215	4,4	6658	4,56			42,36	29,18	9,63	2,84	4,18	3,68	0,17	0,70