

Universidade Federal de Ouro Preto

Escola de Minas
Programa de Pós-Graduação em Engenharia Civil
PROPEC

Dissertação

**Aprendizado de máquina
aplicado à construção civil:
estimativa da resistência à
compressão de concretos de
escória de aciaria**

Rúben El-Katib Penido

Ouro Preto

2022



Aprendizado de Máquina Aplicado à Construção Civil: Estimativa da Resistência à
Compressão de Concretos de Escória de Aciaria

Rúben El-Katib Penido

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Ouro Preto, como requisito parcial para obtenção do título de Mestre em Engenharia Civil.

Área de concentração: Engenharia Estrutural e de Materiais

Orientadora: Prof^a. Dr.^a Júlia Castro Mendes

Coorientador: Prof. Dr. Alexandre Abrahão Cury

Ouro Preto

2022

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

P411a Penido, Ruben El Katib.

Aprendizado de máquina aplicado à construção civil [manuscrito]:
estimativa da resistência à compressão de concretos de escória de
aciaria. / Ruben El Katib Penido. Rúben E-Katib Penido. - 2022.
120 f.

Orientadora: Profa. Dra. Júlia Castro Mendes.

Coorientador: Prof. Dr. Alexandre Abrahão Cury.

Dissertação (Mestrado Acadêmico). Universidade Federal de Ouro
Preto. Departamento de Engenharia Civil. Programa de Pós-Graduação
em Engenharia Civil.

Área de Concentração: Estruturas e Construção.

1. Escória (Metalurgia) - Escória de Aciaria. 2. Concreto - Resistência à
Compressão. 3. Aprendizado do computador. I. Penido, Rúben E-Katib. II.
Cury, Alexandre Abrahão. III. Mendes, Júlia Castro. IV. Universidade
Federal de Ouro Preto. V. Título.

CDU 624.01

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



FOLHA DE APROVAÇÃO

Rúben El-Katib Penido

Aprendizado de máquina aplicado à construção civil: estimativa da resistência à compressão de concretos de escória de aciaria

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Mestre em Engenharia Civil

Aprovada em 08 de Abril de 2022

Membros da banca

Prof^a. Dr.^a Júlia Castro Mendes - Orientadora (Universidade Federal de Ouro Preto)
Prof. Dr. Alexandre Abrahão Cury - Coorientador - (Universidade Federal de Juiz de Fora)
Prof. Dr. José Maria Franco de Carvalho - (Universidade Federal de Viçosa)
Prof^a. Dr.^a Tatiana Barreto dos Santos - (Universidade Federal de Ouro Preto)

Júlia Castro Mendes, orientadora do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 20/04/2022



Documento assinado eletronicamente por **Julia Castro Mendes, PROFESSOR DE MAGISTERIO SUPERIOR**, em 28/04/2022, às 15:38, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0316512** e o código CRC **DB4D55AD**.

“O que sabemos é uma gota, o que ignoramos é um oceano”.

Isaac Newton

AGRADECIMENTOS

Ao Senhor Deus Todo-Poderoso, que me sustentou mesmo quando eu não tinha mais forças, dando-me sabedoria e fornecendo condições para que eu vencesse em tudo o que seria útil na minha vida.

Aos meus pais, por sempre terem sonhado junto comigo e sempre terem me dado amor, conselhos e apoio financeiro.

Aos meus irmãos, Miriam e Dudu, por todo encorajamento.

À minha noiva, Ludmila, por todo amor, paciência, cumplicidade e por ter presenciado, desde a minha graduação, todo o meu desenvolvimento com tanta compreensão e otimismo.

À toda minha família pelas orações e por todo amor e carinho que sempre tiveram para comigo.

Aos meus amigos Júlio Cezar de Oliveira e Luiz Fernando Rispoli Alves que são desde a minha graduação, pessoas presentes e instrumentos de Deus na minha vida.

À CAPES, o presente trabalho foi realizado com apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES).

Aos meus orientadores, Dr^a. Júlia Castro Mendes e Dr. Alexandre Abrahão Cury, pelos conhecimentos passados, pela atenção, paciência e dedicação e por terem acreditado em meu potencial durante todo o desenvolvimento deste trabalho.

Ao discente Rafael Christian por ter contribuído com todo o seu esforço e conhecimento.

À doutoranda Laís Cristina Barbosa Costa e seu orientador, Prof. Dr. Ricardo André Fiorotti Peixoto, por fornecerem os dados experimentais para validação dos modelos desenvolvidos.

RESUMO

Nos últimos anos, estudos vêm sendo conduzidos visando disseminar a reutilização de escória de aciaria como agregado para concretos. Entretanto, a ausência de metodologias para obtenção de traços de concretos de escória de aciaria tem dificultado as pesquisas e comprometido o seu uso em larga escala. Além disso, as metodologias convencionalmente adotadas para a definição de traços de concreto envolvem tabelas empíricas e a necessidade de se moldar e romper corpos de prova, demandando tempo e recursos. Neste contexto, o presente trabalho teve como objetivo desenvolver modelos baseados em aprendizado de máquinas para a previsão da resistência à compressão de concretos de escória de aciaria a partir de seus traços. Para este fim, foi realizado um levantamento de dados de concretos de escória de aciaria na literatura e aplicadas quatro técnicas de aprendizagem de máquina: regressão por vetores suporte (SVR), redes neurais artificiais (ANN), árvore de decisão com algoritmo de *boosting* (XGBoost) e processo gaussiano de regressão (GPR). Os resultados foram avaliados por meio de três indicadores: erro absoluto médio (MAE), erro quadrático médio (RMSE) e coeficiente de determinação (R^2). Numa primeira etapa, os modelos com o banco de dados elaborado foram validados de forma cruzada ($k = 10$). Em seguida, foram utilizados dados experimentais para validar os modelos construídos. Na primeira etapa, o modelo que alcançou o melhor desempenho foi o ANN, com R^2 de 0,79, com os demais variando entre 0,68 e 0,73. Os MAEs variaram entre 4,73 e 5,51 MPa. No entanto, a validação experimental obteve resultados insatisfatórios - os modelos de GPR, XGBoost e SVR apresentaram valores de R^2 negativos. Isso mostra que o tamanho do banco de dados e a variabilidade do resíduo estudado influenciam significativamente a qualidade dos modelos propostos. Desse modo, o presente trabalho traz os primeiros passos para o desenvolvimento de estratégias de desenvolvimento de traços para concretos não-convencionais. Em última análise, buscamos reduzir o impacto das indústrias siderúrgicas no meio ambiente e contribuir para o entendimento dos fatores que influenciam os traços de concreto.

Palavras-chave: Escória de Aciaria; Resistência à Compressão; Traço do Concreto; Aprendizado de Máquina Supervisionado; Concretos de resíduos.

LISTA DE FIGURAS

Figura 1 - Rompimento de Corpo de Prova à Compressão. Fonte: Bezerra (2007)	22
Figura 2 - Ensaio de Compressão Mecânica. Fonte: Pinto (2017).....	22
Figura 3 – Fenômeno de Segregação do Concreto. Fonte: Revista Construa (2020).....	27
Figura 4 – Fenômeno de Exsudação no Concreto. Fonte: Catusso et al. (2015)	27
Figura 5 - Ensaio de Abatimento de Tronco de Cone. Fonte: Borges (2019)	28
Figura 6 - Curvas de Abrams - Método ABCP. Fonte: Rodrigues (1990)	32
Figura 7 - Aprendizagem de máquina supervisionada: informações sobre altura, largura e cor são extraídas de um banco de dados, com a finalidade de detectar padrões e assim prever dados no futuro. Fonte: autor, adaptado de Murphy (2012)	38
Figura 8 - Possíveis hiperplanos de separação (em verde) e hiperplano ótimo, maximizando a margem (m). Fonte: autor, adaptado de Gonçalves (2015)	40
Figura 9 - A geometria de um vetor suporte em classificação binária. Os pontos circulados em laranja são os vetores suportes. A máquina de vetores suportes encontra o limite de decisão que maximiza a margem (m). Fonte: autor, adaptado de Flach (2012)	40
Figura 10 - Exemplos de um padrão linearmente separável (à esquerda) e outro não linearmente separável (à direita). Fonte: autor, adaptado de Gonçalves (2015)	41
Figura 11 - Um modelo de neurônio matemático. Em que n_{jk} representa o sinal de entrada do neurônio j e w_{jk} é o peso correspondente à entrada. Fonte: autor, adaptado de Chen et al. (2017).....	44
Figura 12 - Representação de uma ANN por alimentação adiante (Feed-Forward). Fonte: autor, adaptado de Chen et al. (2017).....	45
Figura 13 – Estrutura de uma Árvore de Decisão. Fonte: autor, adaptado de Garcia (2003)	47
Figura 14 - Visão Geral da Metodologia. Fonte: autor	58

Figura 15 – Funcionamento do Processo de Validação Cruzada para 10 subconjuntos ($k=10$). Fonte: autor.....66

LISTA DE TABELAS

Tabela 1 - Composição Química média das Escórias de Aciaria da literatura. Fonte: Martins et al. (2021)	18
Tabela 2 - Consumo de Água de Amassamento do Concreto em Função do Abatimento e da Dimensão Máxima Característica do Agregado. Fonte: autor, adaptado de Rodrigues (1990).....	31
Tabela 3 - volume compactado seco (VCS) de agregado graúdo por m ³ de concreto em Função do MF e da DMC do agregado graúdo. Fonte: autor, adaptado de Rodrigues (1990).....	33
Tabela 4 - Dados do levantamento de literatura. Fonte: autor	59
Tabela 5 - Fatores de correção com tamanho e formas para concretos de resistência normal. Fonte: autor, adaptado de Yi et al. (2006)	61
Tabela 6 - Descrição da base de dados completa. Fonte: autor.....	62
Tabela 7 - Descrição da base de dados com resistência somente aos 28 dias. Fonte: autor	63
Tabela 8 - Descrição da base de dados de valores experimentais. Fonte: Costa (2021).....	67
Tabela 9 - Métricas de avaliação para cada modelo do banco de dados completo (todas as idades). Fonte: autor.....	69
Tabela 10 - Métricas de avaliação para cada modelo do banco de dados para 28 dias. Fonte: autor	70
Tabela 11 – 05 traços referentes aos maiores erros que se repetem em todos os modelos.....	72
Tabela 12 – Validação experimental dos modelos, usando como treinamento o banco de dados para 28 dias. Fonte: autor	73
Tabela 13 – Revisão da Literatura. Fonte: autor.....	90
Tabela 14 – Banco de Dados Completo. Fonte: autor	1
Tabela 15 - Banco de Dados Experimentais. Fonte: adaptado de Costa et al. (2021).....	1

LISTA DE SIGLAS

ABCP – Associação Brasileira de Cimento Portland

A/C – Fator água/ cimento

ANN – Redes Neurais Artificiais (do inglês, *Artificial Neural Network*)

BOF -- Escória de forno com conversores à oxigênio (*Blast Oxygen Furnace*)

CART – Árvores de Classificação e Regressão (do inglês, *Classification and Regression Tree*)

DMF – Dimensão Máxima Característica

EAF – Forno Elétrico à Arco (do inglês, *Electric Arc Furnace*)

LD - *Linz-Donawitz*

MAE – Erro Absoluto Médio (do inglês, *Mean Absolute Error*)

MEF – Método dos Elementos Finitos

MF – Módulo de Finura

MLP – Rede Neural Perceptron multicamadas (do inglês, *Multilayer Perceptron Neural Network*)

RMSE – Raiz do Valor Quadrático Médio (do inglês *Root Mean Squar Error*)

SVM – Máquinas de Vetores Suporte (do inglês, *Support Vector Machine*)

SUMÁRIO

1	Introdução	14
1.1	Objetivo	17
1.1.1	Objetivos Específicos.....	17
2	Revisão Bibliográfica.....	18
2.1	Escória de Aciaria.....	18
2.2	Propriedades do Concreto.....	21
2.2.1	Resistência.....	21
2.2.2	Durabilidade	25
2.2.3	Trabalhabilidade.....	26
2.3	Dosagem do concreto.....	28
2.3.1	Método de Dosagem de Concretos ABCP	30
2.3.2	Consumo de Cimento	35
2.4	O Aprendizado de Máquina (<i>Machine Learning</i>)	37
2.4.1	Tipos de Aprendizado de Máquina.....	37
2.4.2	Máquinas de Vetores Suporte (SVM).....	39
2.4.3	Redes Neurais Artificiais (ANN)	43
2.4.4	Algoritmo de <i>Boosting</i> (XGBoost)	46
2.4.5	Processo Gaussiano de Regressão (GPR).....	51
2.5	Aplicações de aprendizagem de máquina em concretos.....	53
2.5.1	Concretos Convencionais	53
2.5.2	Concretos de Escória de Aciaria	55
3	Metodologia.....	58
3.1	Visão geral da metodologia	58
3.2	Construção do banco de dados	59

3.2.1	Levantamento sistemático de referências.....	59
3.2.2	Padronização dos dados.....	60
3.2.3	Pré-processamento da base de dados	62
3.3	Construção dos Modelos	63
3.3.1	Algoritmos adotados	63
3.3.2	Normalização	65
3.3.3	Validação Cruzada.....	65
3.4	Validação Experimental	66
3.5	A Qualidade de Ajuste do Modelo	67
4	Resultados	69
4.1	Criação dos Modelos (com validação cruzada)	69
4.1.1	Métricas de avaliação	69
4.1.2	Discussão.....	70
4.2	Validação experimental	73
4.2.1	Métricas de avaliação	73
4.2.2	Discussão.....	74
5	Conclusões.....	75
5.1	Sugestões para trabalhos futuros	76
6	Referências	78
7	Apêndices	89
7.1	Artigos	89
7.2	Revisão da literatura realizada pelo autor	90
7.3	Banco de dados elaborado pelo autor	7
7.4	Banco de Dados Experimentais de Validação.....	1
7.5	Referência dos Artigos do Banco de Dados da Literatura	7

1 INTRODUÇÃO

O impacto ambiental provocado pela indústria siderúrgica sempre foi considerável, devido ao seu grande consumo de insumos e energia (GEYER, 2001). Além disso, a produção de aço gera diversos resíduos, como a escória de aciaria, que normalmente é depositada em pátios a céu aberto (DE FREITAS, 2018). A escória de aciaria é um subproduto gerado durante o refino do aço em siderurgias. Ela é obtida na etapa de redução do ferro, na forma de gusa líquido ou de ferro esponja (RODRIGUES, 2007).

A produção de aço mundial em 2019 foi de 1,87 bilhões de toneladas (WORLD STEEL ASSOCIATION, 2019) enquanto o Brasil, em 2019, produziu 32,2 milhões de toneladas. Tem-se que, para cada tonelada de aço produzido, são geradas em torno de 150 kg de escória de aciaria (LAREX-USP, 2020). Com base nesse dado, pode-se estimar que só em 2019 foram geradas no Brasil 4,83 milhões de toneladas de escória de aciaria.

O descarte desses resíduos industriais apresenta inúmeros impactos sociais e ambientais, tais como: geração de poeira, risco de contaminação do solo e cursos d'água e elevado custo para transporte e preparação da área de descarte (US\$ 20 a US\$ 30 por tonelada de resíduo depositado) (GEYER, 2001; G1, 2018). Entretanto, pesquisas indicam que essas escórias chegam a possuir características mecânicas iguais ou superiores aos agregados naturais (MARTINS, CARVALHO, *et al.*, 2021). Com o intuito de buscar um maior aproveitamento desse resíduo, pesquisadores ao redor do mundo desenvolvem estudos para a sua utilização em matrizes cimentícias, como concretos e argamassas (GAMA, NETO e RABELO, 2013; DINIZ, CARVALHO, *et al.*, 2017; MARTINS, CARVALHO, *et al.*, 2021);

O concreto adotado em estruturas convencionais de concreto armado é normalmente projetado para resistir aos esforços de compressão. Essa característica está diretamente ligada à segurança estrutural e durabilidade destas estruturas. Por isso, os métodos de dosagem de concretos visam alcançar uma determinada resistência à compressão mínima, definida em projeto, a partir do dimensionamento dos seus componentes principais, a saber: cimento Portland, agregado graúdo, agregado miúdo, água e, opcionalmente, aditivos e

adições. A grande variedade e heterogeneidade dos materiais que podem compor a dosagem é justamente uma das dificuldades em se obter um traço ao mesmo tempo seguro e econômico (TUTIKIAN e HELENE, 2011).

Segundo Tutikian e Helene (2011), não há no Brasil um consenso textual em forma de norma sobre os procedimentos e parâmetros de dosagem de concretos. Por conseguinte, vários pesquisadores propõem seus próprios métodos de dosagem que muitas vezes se confundem com uma recomendação da instituição pela qual foram publicados. Dentre estes, podem ser citados:

- Método de dosagem IPT (Instituto de Pesquisas Tecnológicas), proposto inicialmente por Ary Frederico Torres (1927), Simão Prizskulnik (1977) e Carlos Tango (1986);
- Método de dosagem INT (Instituto Nacional de Tecnologia), no Rio de Janeiro, proposto por Fernando Luiz Lobo Carneiro (1937);
- Método de dosagem ITERS (Instituto Tecnológico do Estado do Rio Grande do Sul), proposto por Eládio Petrucci (1985);
- Método ABCP (Associação Brasileira de Cimento Portland), proposto inicialmente por Ary Torres e Carlos Rosman (1956), que atualmente adota uma adaptação do método americano do ACI (do inglês, *American Concrete Institute*);

Nota-se que essas metodologias foram propostas há décadas e, em sua maioria, baseiam-se em gráficos e tabelas obtidos empiricamente. Assim, após a determinação do traço por esses métodos, é necessário testar sua resistência real e realizar ajustes, caso necessário, em um processo iterativo. Essa resistência é obtida pelo ensaio de ruptura de corpos-de-prova, geralmente após 28 dias de cura, sob procedimentos padrão da NBR 5739 (ABNT, 2018).

De modo geral, tais metodologias para a determinação do traço demandam um intenso consumo de recursos naturais e humanos e testes em laboratório, além do tempo de moldagem e cura (BONIFÁCIO, MENDES, *et al.*, 2019). Assim, são necessários processos mais eficientes, atuais e otimizados - além de seguros - para a determinação do traço do concreto. Ademais, faltam metodologias para a elaboração de traços de concretos não-convencionais, principalmente aqueles baseados em resíduos, como os de escória de aciaria, já que as características

particulares desses subprodutos fazem com que os métodos tradicionais não sejam tão precisos (MARTINS, CARVALHO, *et al.*, 2021).

Diante deste cenário, surge a possibilidade de utilização de técnicas baseadas em aprendizagem de máquina para a dosagem de concretos. Aprendizagem de máquina é um conjunto de métodos computacionais que possuem a capacidade de detectar padrões nos dados de forma autônoma e então usar esses padrões descobertos para prever resultados futuros (MURPHY, 2012). Tais técnicas estão sendo cada vez mais utilizadas para simular o comportamento do concreto, tendo se tornado uma importante linha de pesquisa na engenharia civil (CHOU, TSAI, *et al.*, 2014).

Como exemplos de aplicações de técnicas baseadas em aprendizagem de máquina aplicadas a concreto, podemos citar o trabalho de Bonifácio *et al.* (2019), que investigaram a aplicação da regressão por vetores suporte (*support vector regression*, em inglês, ou SVR) a fim de prever as propriedades mecânicas do concreto, obtendo um desvio padrão médio de 5,46% para a resistência à compressão e 2,48% para o módulo de elasticidades. Um outro exemplo é o projeto de Chou *et al.* (2014), que avaliou o aprendizado de máquinas em simulações da resistência à compressão de concretos de alto desempenho, fazendo uso das técnicas de redes neurais perceptron multicamadas (*multilayer perceptron*, em inglês, ou MLP), máquinas de vetores suporte (*support vector machine*, em inglês, ou SVM), árvores de classificação e regressão e regressão linear. Os resultados indicaram que os dois melhores modelos de aprendizagem foram o SVM, com desvios entre 1,31 e 3,75 MPa, e o MLP, com desvios entre 4,00 e 4,28 MPa. Chou *et al.* (2016), por sua vez, buscaram estimar a resistência ao cisalhamento em vigas profundas de concreto armado com a utilização de um método que combina o Algoritmo Colônia de Vagalumes e SVM com mínimos quadrados. O desempenho do algoritmo foi avaliado por meio de algumas métricas, obtendo um coeficiente de determinação (R^2) de 0,941. Estes artigos reforçam a viabilidade de aplicação de aprendizagem de máquina para estimar as propriedades do concreto.

1.1 Objetivo

Nesse cenário, o presente trabalho busca desenvolver modelos baseados em aprendizado de máquina para estimar a resistência à compressão de concretos de escória de aciaria a partir dos componentes de seu traço.

1.1.1 Objetivos Específicos

O presente trabalho possui os seguintes objetivos específicos:

- A partir do levantamento de uma base de dados de concretos de escória na literatura, investigar os modelos de regressão mais adequados para estimar a resistência dos concretos.
- Verificar a eficácia dos modelos e a sua capacidade de generalização por meio da validação com dados experimentais.

2 REVISÃO BIBLIOGRÁFICA

2.1 Escória de Aciaria

Para a produção do aço, o processo mais utilizado nas usinas siderúrgicas integradas é a conversão do ferro gusa no processo *Linz-Donawitz* (LD) ou *Blast Oxygen Furnace* (BOF) (INSTITUTO AÇO BRASIL, 2021). Já nas usinas semi-integradas, o ferro obtido é usado em fornos elétricos (EAF, do inglês *Electric Arc Furnace*) (DE FREITAS, 2018). Cada processo de fabricação gera um tipo específico de escória de aciaria, LD, BOF ou EAF. A Tabela 1 mostra a composição química das escórias de aciaria BOF e LD de diversas siderurgias brasileiras.

Tabela 1 - Composição Química média das Escórias de Aciaria da literatura. Fonte: Martins et al. (2021)

Composição Química das Escórias de Aciaria da Literatura						
Tipo de Escória	BOF			EAF		
	Mínimo (%)	Médio (%)	Máximo (%)	Mínimo (%)	Médio (%)	Máximo (%)
CaO	33,97	42	57,44	16,90	31,95	53,31
Fe Total (Fe ₂ O ₃ /FeO/Fe)	5,24	23,80	38,06	1,07	29,34	54,72
SiO ₂	7,74	15	36,33	10,36	17,79	39,76
Al ₂ O ₃	0,33	3,53	11,38	1,55	7,56	18,98
MgO	1,56	7	11,20	1,86	5,63	18,95
MnO	0,42	3,02	10,31	0,80	4,18	5,87
Na ₂ O +K ₂ O	0,02	0	1,34	0,10	0,26	0,59
SO ₃	0,01	0,47	2,70	0,01	0,36	0,69
Cr ₂ O ₃	0,11	1	3,14	0,54	1,83	4,01
V ₂ O ₅	0,03	0,90	6,51	0,06	0,14	0,37
TiO ₂	0,16	1	1,78	0,04	0,72	2,11
P ₂ O ₅	0,33	1,76	7,14	0,05	0,79	1,83
Outros Óxidos	0,01	3	14,84	0,06	0,65	1,60

As escórias de aciaria podem ser utilizadas como agregados no concreto, no entanto, essa utilização é reduzida por conta de possíveis reações expansivas (GUMIERI, PAGNUSSAT e DAL MOLIN, 2000). Os compostos que mais contribuem para a expansão são os óxidos de cálcio e magnésio (CaO e MgO). Quando em contato com a água, esses compostos se transformam em hidróxidos de cálcio e magnésio (Ca(OH)₂ e Mg(OH)₂), aumentando o seu volume, gerando tensões e podendo ocasionar trincas e fissuras no concreto (GUMIERI, PAGNUSSAT e DAL MOLIN, 2000). Para minizar esse fenômeno de expansão, é realizado no Brasil o tratamento por intemperismo, incluindo vários ciclos de molhagem e aeração das escórias, de modo que a hidratação dos óxidos expansivos ocorre antes da incorporação da escória na matriz cimentícia (RODRIGUES, 2007).

Além disso, as escórias possuem um alto teor de ferro metálico, cujos estágios de corrosão e oxidação também contribuem para a sua expansão dentro da matriz cimentícia (FARIA, 2007). Dessa forma, o beneficiamento da escória também conta com processos de separação magnética, que possuem a finalidade de separar essas partículas suscetíveis à atração magnética. A fração metálica recuperada é vendida de volta para o ciclo de produção do aço, o que cobre os custos desse processo e ainda gera lucro (GONÇALVES, FONTES, *et al.*, 2016). Em seguida, a fração não metálica é submetida à britagem e classificada granulométricamente. A partir disso, é possível implementá-la como substituta dos agregados naturais em elementos de concreto pré-moldado, pavimentação, etc (MARTINS, CARVALHO, *et al.*, 2021).

São exemplos de aplicações de escória de aciaria na Construção Civil:

- Martins et al. (2021) – O artigo realizou uma revisão sobre o uso de escória de aciaria como agregado em compósitos cimentícios. A pesquisa abrangeu ensaios para avaliar o desempenho desses componentes em relação à durabilidade, resistência à ataques por cloretos, à carbonatação, à compressão mecânica, entre outros. Os resultados permitiram concluir que os agregados de escória de aciaria podem proporcionar maior durabilidade e maior resistência mecânica à matriz cimentícia.
- Tubino (2001) – O artigo teve como objetivo apontar as potencialidades do uso de escória de aciaria EAF moída como adição ao

cimento Portland comum. O estudo realizou ensaios de expansibilidade, pozolanicidade, resistência à compressão e profundidade de carbonatação com a finalidade de analisar a viabilidade da escória de aciaria como adição ao concreto. Os resultados comprovaram que é viável a utilização de até 10% de escória de aciaria EAF, independentemente do tempo de estocagem da escória;

- De Freitas, Sousa, et al. (2018) – O artigo teve como objetivo principal avaliar a viabilidade da substituição total dos agregados naturais e ligantes por escória de aciaria BOF na fabricação de tijolos maciços. Os resultados permitiram afirmar que há viabilidade técnica e ambiental e que a reciclagem desse resíduo pode ser promissora;

- Gama, Neto e Rabelo (2013) – O trabalho verificou a substituição a partir de diferentes teores de agregados miúdos por escória de aciaria proveniente do forno panela (uma outra forma de fabricação). Os resultados permitiram concluir que as substituições de 30, 40 e 50% permitiram o ganho de propriedades mecânicas, a obtenção de resistência à compressão de acordo com o traço estabelecido, além de propiciar a redução dos custos finais.

- Polisseni (2005) – A tese teve como objetivo estudar a viabilidade técnica em se utilizar escória de aciaria EAF, submetida inicialmente a um processo especial de moagem, como material cimentício em argamassas. O trabalho concluiu que as argamassas criadas obtiveram resultados satisfatórios com relação à resistência à compressão, durabilidade e penetração de íons cloretos;

- Souza (2007) – A dissertação buscou avaliar o potencial de utilização de escória de aciaria em substituição aos agregados naturais na fabricação de elementos de pavimentação intertravada industrial e não-industrial. Os resultados permitiram concluir que esses resíduos, quando ajustados à composição granulométrica, possuem potencial de serem usados como matéria-prima na produção dessas peças de pavimentação;

Em relação à toxicidade das escórias, segundo a NBR 10004 (ABNT, 2004) os resíduos sólidos podem ser divididos em duas classes: I (perigosos) e II (não-perigosos), sendo esta última subdividida em II-A (não-inertes) e II-B (inertes – a

classificação mais benigna). De acordo com a NBR 10004 (ABNT, 2004) os resíduos não-perigosos não apresentam risco à saúde pública, não provocam mortalidade, incidência de doenças ou acentuam seus índices. Ainda de acordo com a NBR 10004 (ABNT, 2004), resíduos não-inertes são aqueles que tem propriedades como biodegradabilidade, combustibilidade ou solubilidade em água. Assim, a partir da análise de lixiviação e solubilidade, as escórias de aciaria foram classificadas por diversos laboratórios como não-perigosas e não-inertes (II-A) (DINIZ, 2009; MIRAOU, ZENTAR e ABRIAK, 2012; DA SILVA, DE SOUZA, *et al.*, 2016). Chaurand *et al.* (2007) estudaram o cromo e o vanádio das escórias de aciaria de Linz, Áustria e afirmaram que o cromo estava presente em uma forma menos estável e menos tóxica, enquanto o vanádio estava presente em sua forma mais tóxica. Diniz *et al.* (2017) e Chaurand *et al.* (2007) afirmaram que tais dados sugerem um risco limitado de toxicidade quando as escórias BOF são estabilizadas, como por exemplo, incorporadas em matrizes cimentícias.

Assim, esses artigos, juntamente com diversos outros da literatura, mostram o potencial de utilização das escórias de aciaria em matrizes cimentícias. Para tanto, é de grande importância que a sua granulometria seja ajustada, que as escórias sejam estabilizadas quimicamente, e que a sua fração metálica tenha sido removida.

2.2 Propriedades do Concreto

2.2.1 Resistência

Segundo Mehta e Monteiro (2014) a resistência à compressão do concreto é a tensão máxima necessária para causar a sua ruptura. Ademais, o corpo de prova pode ser considerado rompido mesmo sem sinais de fratura externa, pelo fato de haver alcançado um estado evoluído de fissuração interna (MEHTA e MONTEIRO, 2014). A Figura 1 demonstra o rompimento de um corpo de prova à compressão.



Figura 1 - Rompimento de Corpo de Prova à Compressão. Fonte: Bezerra (2007)

A resistência à compressão de corpos de prova de concreto é obtida no Brasil por meio do ensaio padronizado pela NBR 5739 – Ensaio de Compressão de Corpos de Prova Cilíndricos. Esse ensaio de compressão é caracterizado por ser de curta duração, sendo normalmente aplicado a corpos de prova cilíndricos de 10 cm de diâmetro e 20 cm de altura (ABNT, 2018). A Figura 2 ilustra o ensaio de compressão mecânica.




Figura 2 - Ensaio de Compressão Mecânica. Fonte: Pinto (2017)

No passado, aceitava-se que a resistência dos materiais e as ações sobre as estruturas podiam ser representadas por valores fixos e não-aleatórios. No entanto, a partir do entendimento de que os componentes do concreto possuem características variáveis, os métodos semiprobabilísticos passaram a ser

adotados para a definição da resistência do concreto (PEREIRA, 2008). Assim, de acordo com Neville (2016), o concreto é uma grandeza que possui alta variabilidade e, portanto, demanda a utilização de probabilidades para a obtenção de informações. A partir disso, a resistência de corpos de prova de concreto passou a ser entendida como uma distribuição normal (Gaussiana), podendo ser descrita pela média e pelo desvio padrão. Em vista disso, os métodos semiprobabilísticos promoveram uma melhor economia e segurança estrutural na produção de concretos (PEREIRA, 2008) .

Segundo Neville (2016), o projeto estrutural baseia-se em uma resistência mínima do concreto. No entanto, como a resistência do concreto não é uma grandeza fixa, devido à heterogeneidade deste compósito e de suas matérias-primas, os engenheiros buscam definir/ alcançar uma resistência média que seja maior do que a mínima na vasta maioria das vezes, de modo a manter a segurança dentro de uma faixa de custo economicamente viável (NEVILLE, 2016). Por exemplo, se uma dada estrutura requer um concreto de 30 MPa aos 28 dias para resistir com segurança às ações que a solicitam (resistência característica, f_{ck}), o engenheiro vai buscar definir um conjunto de materiais que atinja uma resistência média (f_{cm}) superior a essa, digamos, 36 MPa. Dessa forma, supondo condições adequadas de mistura e lançamento, a grande maioria dos corpos-de-prova vai atingir resistências individuais próximas a 36 MPa, como 35,4 MPa ou 36,8 MPa. Somente uma quantidade ínfima resultará em resistências inferiores a 30 MPa.

Dessa forma, com base na distribuição estatística, houve a formulação da resistência característica (f_{ck}). A resistência característica é o valor estabelecido no projeto estrutural e leva em consideração de que nenhum valor é absoluto, ou seja, sempre existirá a probabilidade de um resultado ser menor do que o mínimo (NEVILLE, 2016). Ainda segundo Neville (2016) essa probabilidade de falha gira em torno 5% quando são considerados resultados individuais, e 1% quando utilizada a média móvel de três resultados. Logo, a resistência característica do concreto (f_{ck}) é definida como o valor no qual estima-se obter um intervalo de confiança de 95% dos resultados acima da resistência mínima de projeto (PEREIRA, 2008) . Ainda segundo Pereira (2008) , é importante ressaltar que a média dos resultados deve ser obtida por meio de corpos de prova provenientes

da mesma betonada e ensaiados à mesma idade. Segundo a NBR 12655 (ABNT, 2015) a resistência à compressão média do concreto pode ser obtida pela equação (1):

$$f_{cm} = f_{ck} + 1,65\sigma \quad (1)$$

onde:

- f_{cm} é a resistência à compressão média, calculada a partir de uma amostra de no mínimo 20 corpos de prova;
- f_{ck} é a resistência à compressão característica do concreto com 5% de probabilidade de falha;
- σ é o desvio padrão, calculado a partir da mesma amostra.

Ainda segundo a NBR 12655 (ABNT, 2015), quando o concreto for elaborado sob as mesmas condições e materiais, o desvio padrão deverá ser calculado para um mínimo de 20 resultados consecutivos obtidos no intervalo de 30 dias, sendo, no mínimo, 2 Mpa. A norma também esclarece que podem ser utilizados valores de desvio padrão de acordo com as condições de preparo do concreto, sendo: 4,0 MPa para a Condição A (todas as classes de concretos); 5,5 MPa para a Condição B (classes C10 a C20); e 7,0 MPa para a Condição C (classes C10 a C15).

Já o *Building Code* da ACI (ACI 318 (2008)) exige que a probabilidade de falha na média móvel de três resultados seja inferior a 1%. A equação (2) elucida essa exigência:

$$f'_{cr} = f'_c + \frac{2,33\sigma}{\sqrt{3}} = f'_c + 1,343\sigma \quad (2)$$

onde:

- f'_{cr} é a resistência à compressão mínima do concreto com 1% de probabilidade de falha;
- f'_c é a resistência à compressão média necessária em uma determinada idade;
- σ é o desvio padrão, calculado a partir da mesma amostra.

Além disso, a ACI 318 (2008) exige a probabilidade de 1% de que um resultado individual tenha uma resistência além de 3,5 MPa inferior à resistência de projeto. A equação (3) ilustra a segunda exigência:

$$f'_{cr} = f'_c - 3,5 + 2,33\sigma \quad (3)$$

onde:

- f'_{cr} é a resistência à compressão característica do concreto com 1% de probabilidade de que um resultado individual tenha uma resistência acima de 3,5 MPa inferior à resistência de projeto;
- f'_c é a resistência à compressão média necessária em uma determinada idade;
- σ é o desvio padrão, calculado a partir da mesma amostra.

Tem-se também a norma britânica Eurocode 2 (2004), cujos corpos de prova ensaiados são cúbicos, com 150 ou 100 cm de lado. Essa norma exige que a probabilidade de falha, na média móvel de dois resultados, seja de até 5%. Além disso, são exigidas duas condições:

- O valor médio de quatro resultados supere em 3 MPa a resistência de projeto;
- Os resultados individuais sejam inferiores em, no máximo, 3 MPa à resistência de projeto.

2.2.2 Durabilidade

Devido à grande diversidade de condições de exposição, ainda não foi possível a criação de um método de dosagem que fornecesse um resultado confiável de durabilidade das estruturas de concreto (NEVILLE, 2016; TUTIKIAN e HELENE, 2011). Assim, apesar da importância da durabilidade dos concretos para as estruturas, por conta de sua complexidade e dependência de múltiplos fatores, não há um método consensual para a sua aferição. De acordo com Neville (2016), durabilidade é uma propriedade que não pode ser negligenciada, pois mesmo um concreto com resistência à compressão adequada deve ser adaptado à realidade do meio ambiente e clima local.

De acordo com Mehta e Monteiro (2014), a porosidade capilar é o atributo que relaciona a resistência e a impermeabilidade das pastas de cimento. Também se demonstrou que a porosidade capilar pode ser controlada pelo fator água/cimento e pelo grau de hidratação (MEHTA e MONTEIRO, 2014). Ademais, segundo Mehta e Monteiro (2014) quando a relação água/cimento é diminuída por meio do aumento do consumo de cimento, maiores são as chances de fissuração por retração térmica e retração por secagem.

Dessa forma, por meio do controle da distribuição granulométrica dos agregados e com o uso de aditivos redutores de água é possível reduzir a quantidade de água de amassamento, reduzindo o fator água/cimento quando exigido pela especificação de resistência e durabilidade (MEHTA e MONTEIRO, 2014).

Logo, o consumo de cimento não é o responsável direto pela durabilidade, mas sim pelo valor do fator água/cimento (a/c); o que, por sua vez, comprovadamente influencia na tanto na resistência quanto na durabilidade. Dessa forma, profissionais buscam atingir concretos mais duráveis pela redução do seu fator a/c, o que indiretamente, em geral, leva a uma maior resistência. No entanto, é questionável que a resistência de um concreto, por si só, possa ser associada diretamente à sua durabilidade (NEVILLE, 2016).

2.2.3 Trabalhabilidade

A trabalhabilidade determinará a facilidade com que a mistura de concreto, no estado fresco, será bombeada ou lançada. Para tanto, cada situação será condicionada pelos projetos arquitetônicos, estruturais, equipamentos utilizados, necessidades de acabamento e condições ambientais (TUTIKIAN e HELENE, 2011). De modo geral, Tutikian e Helene (2011) explicitam que uma mistura deverá possuir trabalhabilidade adequada para ocupar todo o espaço das fôrmas e entre as armaduras, sendo ao mesmo tempo coesa, a fim de que não haja problemas como segregação (bicheiras), exsudação, etc. A Figura 3 exemplifica o fenômeno da segregação do concreto, já a Figura 4 ilustra o fenômeno da exsudação.



Figura 3 – Fenômeno de Segregação do Concreto. Fonte: Revista Construa (2020)



Figura 4 – Fenômeno de Exsudação no Concreto. Fonte: Catusso et al. (2015)

De acordo com Neville (2016), a coesão depende fortemente da proporção de partículas finas na mistura. A coesão ideal da mistura permitirá o seu lançamento e compactação sem que haja segregação ou os outros problemas mencionados anteriormente. Portanto, um proporcionamento dos materiais que não atende à trabalhabilidade conveniente compromete o objetivo da dosagem do concreto (NEVILLE, 2016). A Figura 5 demonstra o ensaio de abatimento do tronco de cone, que possui a finalidade de avaliar a trabalhabilidade do concreto, definido pela NBR 16889 (ABNT, 2020).



Figura 5 - Ensaio de Abatimento de Tronco de Cone. Fonte: Borges (2019)

2.3 Dosagem do concreto

Dosagem do concreto é o processo de determinação da proporção entre os componentes do concreto. Esse processo possui a finalidade de se produzir um concreto que atenda às necessidades de projeto, de maneira mais econômica possível (NEVILLE, 2016). Segundo Tutikian e Helene (2011), essa proporção pode ser expressa em volume ou massa, sendo preferível quando expressa em massa seca.

No processo de dosagem, os dois principais requisitos a serem determinados são 1) a trabalhabilidade do concreto no estado fresco e 2) a resistência do concreto no estado endurecido em uma idade determinada, normalmente 28 dias (MEHTA e MONTEIRO, 2014). É importante ressaltar que, embora a resistência

do concreto à tração por flexão também seja comum em projetos de pavimentação, a resistência do concreto à compressão é especificada com mais regularidade (TUTIKIAN e HELENE, 2011).

Do ponto de vista econômico, o cimento é o componente mais caro do concreto, chegando a ser dezenas de vezes mais caro do que os agregados (CAIXA ECONÔMICA FEDERAL, 2021). Além disso, grande parte das manifestações patológicas em estruturas de concreto são originadas ou acentuadas por reações com os produtos de hidratação do cimento (SOUZA e RIPPER, 1998). E é necessário ressaltar que só a produção do cimento em 2016 foi responsável por gerar cerca de 2,2 bilhões de toneladas de CO₂, um dos gases responsáveis por agravar o aquecimento global, correspondendo a 8% das emissões do planeta (BBC, 2018). Por isso, durante a definição do traço é necessário que se tenha, dentro do possível, o menor consumo de cimento por metro cúbico de concreto (NEVILLE, 2016).

Para se obter essa quantidade de cimento, agregados, água, aditivos e adições de forma segura, econômica e sustentável, pesquisadores ao redor do mundo desenvolvem seus métodos de dosagens. No Brasil, atualmente não há consenso ou norma nacional sobre os procedimentos de dimensionamento de misturas de concreto (TUTIKIAN e HELENE, 2011). Os métodos de dosagem mais adotados foram publicados por instituições de pesquisa de renome. Alguns dos mais famosos, como mencionado anteriormente, são o da ABCP e IPT. Além disso, por conta da grande extensão territorial, o que leva a uma ampla variabilidade e diferença entre os materiais disponíveis em cada região, cada profissional adota o método que julga ser o mais eficaz para sua realidade.

Com relação às normas brasileiras, a NBR 12655 (ABNT, 2015) traz recomendações sobre o preparo, controle, recebimento e aceitação do concreto e é a única norma com alguns limites para a proporção de materiais. Além disso, ela também estabelece o fator a/c máximo (0,65 a 0,45) e o consumo mínimo de cimento (260 kg/m³ a 360 kg/m³) de acordo com a agressividade da região ou a condição de exposição do concreto (ABNT, 2015). A norma também determina que, para concretos com resistência à compressão igual ou acima de 20 MPa, a composição do concreto deva ser definida por uma metodologia de projeto de mistura racional e experimental. Por fim, a NBR 12655 (2015) fornece o cálculo

da resistência alvo, que deve ser feito de acordo com as condições de variabilidade da construção.

Recentemente, Marmitti, Bez et al. (2016), realizaram um estudo comparativo de quatro métodos de dosagem de concretos: Britânico, Americano, ABCP/ACI e CIENTEC. Neste estudo foi possível perceber que, mesmo fixadas a resistência à compressão e a trabalhabilidade, foram observadas grandes diferenças nos traços resultantes. Essas diferenças foram destacadas entre os teores de argamassa, nas relações entre água e materiais secos, e entre agregado miúdo e agregado graúdo. Apesar disso, não houve grandes diferenças no consumo de cimento obtido pelos quatro métodos (MARMITTI, BEZ, *et al.*, 2016).

2.3.1 Método de Dosagem de Concretos ABCP

Como ilustração, vamos explicar nesse trabalho o método de dosagem da ABCP. Ele foi elaborado pelo Eng. Públio Penna Firme Rodrigues, publicado em 1984 pela Associação Brasileira de Cimento Portland (ABCP) e revisado em 1995. O método consiste em uma adaptação do método americano (norma ACI 211.1), às condições e materiais existentes no Brasil, possibilitando a dosagem de concretos convencionais (RODRIGUES, 1990; BOGGIO, 2000). É importante mencionar que as tabelas e gráficos que compõem o método foram elaboradas a partir de valores médios de resultados experimentais, com base em agregados que se enquadram nos limites impostos pela NBR 7211 (ABNT, 2009) (RODRIGUES, 1990).

Com a finalidade de se utilizar o método ABCP, é necessária a especificação de alguns parâmetros do concreto. O primeiro parâmetro a ser definido é a consistência ou trabalhabilidade do concreto, obtida, como visto anteriormente, pelo ensaio de abatimento de tronco de cone (*slump*) (NEVILLE, 2016).

Além do abatimento, é necessário também o valor da Dimensão Máxima Característica (DMC), sendo definida pela NBR 7211 (ABNT, 2009) como “a abertura nominal, em milímetros, da malha da peneira da série normal ou intermediária na qual o agregado apresenta uma porcentagem retida acumulada igual ou imediatamente inferior a 5% em massa”. A limitação da DMC é relevante para evitar que agregados graúdos maiores que o cobrimento do elemento se

prendam entre as formas e as armaduras, ou entre barras da armadura, gerando vazios e bicheiras. A DMC também deverá levar em conta o tipo, as dimensões das peças estruturais e os espaçamentos entre as barras da armadura, de acordo com a NBR 6118 (ABNT, 2014).

Em função então do abatimento do concreto e da DMC, é estimado o consumo de água de amassamento do concreto por meio da Tabela 2 (RODRIGUES, 1990). Também é recomendado pelo método que sejam feitos uma verificação experimental e o ajuste do consumo de água por meio da equação (4).

Tabela 2 - Consumo de Água de Amassamento do Concreto em Função do Abatimento e da Dimensão Máxima Característica do Agregado. Fonte: autor, adaptado de Rodrigues (1990)

Consumo de Água de Amassamento (kg/m ³)					
Abatimento [mm]	Dimensão Máxima Característica do Agregado Graúdo (DMC) [mm]				
	9,5	19	25	32	38
40 a 60	220	195	190	185	180
60 a 80	225	200	195	190	185
80 a 100	230	205	200	195	190

$$C_{ar} = C_{ai} * \left(\frac{ST_r}{ST_i} \right)^{0,1} \quad (4)$$

onde:

- C_{ar} é o consumo de água requerido;
- C_{ai} é o consumo de água inicial;
- ST_r é o abatimento requerido;
- ST_i é o abatimento inicial.

A próxima etapa do método é a fixação da relação a/c do concreto. Para isso são utilizadas as Curvas de Abrams e, como entrada, a resistência à compressão

do concreto requerida a 28 dias e o tipo de cimento (RODRIGUES, 1990). A Figura 6 ilustra as Curvas de Abrams utilizada no método ABCP.




Figura 6 - Curvas de Abrams - Método ABCP. Fonte: Rodrigues (1990)

A seguinte etapa é a obtenção do Consumo de Cimento. Dessa forma, a partir dos dados de consumo de água e da relação a/c é possível de se obter o consumo de cimento por meio da equação (5) (RODRIGUES, 1990):

$$C_{cim} = \frac{C_{agua}}{a/c} \quad (5)$$

onde:

- C_{cim} é o consumo de cimento (kg/m^3);
- C_{agua} é o consumo de água (L/m^3);
- a/c é a relação água/ cimento.

A próxima etapa é calcular o consumo de agregado graúdo (C_b) em função de sua DMC e Módulo de Finura (MF). O MF é definido como a soma das porcentagens retidas acumuladas nas peneiras da série normal até a maior peneira utilizada, dividido por 100 (NEVILLE, 2016). A partir desses dados, obtém-

se o volume compactado seco (V_{cs}) por meio da Tabela 3 (RODRIGUES, 1990).
 Nota: o volume de agregado compactado seco refere-se à mistura de todos os tipos de brita que entram na composição do concreto.

Tabela 3 - volume compactado seco (V_{cs}) de agregado graúdo por m^3 de concreto em Função do MF e da DMC do agregado graúdo. Fonte: autor, adaptado de Rodrigues (1990)

Volume Compactado Seco (V_{cs}) de Agregado Graúdo por m^3 de Concreto					
Módulo de Finura (MF)	Dimensão Máxima Característica do Agregado Graúdo (DMC) [mm]				
	9,5	19	25	32	38
1,8	0,645	0,77	0,795	0,82	0,845
2,0	0,625	0,75	0,775	0,80	0,825
2,2	0,605	0,73	0,755	0,78	0,805
2,4	0,585	0,71	0,735	0,76	0,785
2,6	0,565	0,69	0,715	0,74	0,765
2,8	0,545	0,67	0,695	0,72	0,745
3,0	0,525	0,65	0,675	0,70	0,725
3,2	0,505	0,63	0,655	0,68	0,705
3,4	0,485	0,61	0,635	0,66	0,685
3,6	0,465	0,59	0,615	0,64	0,665

Logo, o consumo de agregado graúdo (C_b) pode ser obtido a partir do volume de agregado compacto seco (V_{cs}) e da massa unitária do agregado (M_u). A equação(6) fornece essa relação (RODRIGUES, 1990):

$$C_b = V_{cs} * M_u \quad (6)$$

Quando já determinados os consumos de água, cimento e agregado graúdo, é possível calcular o consumo de agregados miúdos para $1m^3$ de concreto, a partir da soma dos volumes de sólidos, isto é, sem levar em consideração os vazios presentes nos materiais (RODRIGUES, 1990). A equação (7) permite encontrar o consumo de agregados miúdos de maneira imediata:

$$V_a = 1 - \left(\frac{C_{cim}}{\gamma_{cim}} + \frac{C_b}{\gamma_b} + \frac{C_{agua}}{\gamma_{\acute{a}gua}} \right) \quad (7)$$

onde:

- V_a é o volume de agregado miúdo (m^3);
- C_{cim} é o consumo de cimento (kg/m^3);
- C_b é o consumo de agregado graúdo (kg/m^3);
- C_{agua} é o consumo de água (L/m^3);
- γ_{cim} é a massa específica do cimento (kg/m^3);
- γ_b é a massa específica do agregado graúdo (kg/m^3);
- $\gamma_{\acute{a}gua}$ é a massa específica da água (kg/m^3).

Tendo em vista o volume de agregados miúdos, é possível agora obter o consumo de agregados miúdos. A equação (8) demonstra como calcular esse valor (RODRIGUES, 1990):

$$C_a = V_a * \gamma_a \quad (8)$$

onde:

- C_a é o consumo de agregado miúdo (kg/m^3);
- V_a é o volume de agregado miúdo (m^3);
- γ_a é a massa específica do agregado miúdo (kg/m^3).

Assim, a partir de todos os parâmetros calculados pelo método ABCP, obtém-se o traço do concreto em massa. É importante salientar que o traço do concreto geralmente é apresentado de maneira unitária em relação ao cimento, como demonstrado pela equação (9). Exemplificando, um traço em massa “1:2:3:0,5” teria, para cada unidade de massa de cimento, 2 unidades de massa de areia, 3 de brita e 0,5 de água.

$$1: \frac{C_a}{C_{cim}} : \frac{C_b}{C_{cim}} : (a/c) \quad (9)$$

onde:

- C_a é o consumo de agregado miúdo (kg/m^3);
- C_b é o consumo de agregado graúdo (kg/m^3);
- C_{cim} é o consumo de cimento (kg/m^3);
- a/c é a relação água/ cimento;

De acordo com Neville (2016), a determinação da proporção exata da mistura por meio de tabelas ou dados computacionais nem sempre é possível ou precisa, por conta da grande variabilidade dos materiais e pela dificuldade em se quantificar muitas de suas propriedades. Um exemplo dessa dificuldade é a definição adequada da granulometria, forma e textura dos agregados. Para isso, são necessárias suposições de combinações ótimas, a produção de corpos de prova experimentais, além de diversos ajustes com base em processos iterativos.

Adicionalmente, condições de umidade dos agregados no canteiro poderão induzir correções no proporcionamento dos materiais (MEHTA e MONTEIRO, 2014). Assim, somente a mistura produzida no canteiro de obras é capaz fornecer as informações do concreto de maneira mais fidedigna, de modo a cumprir as especificações do projeto em questão (NEVILLE, 2016). Dessa forma, independentemente da metodologia de dosagem adotada, a verificação da resistência real do concreto, por meio da moldagem de corpos de prova durante o lançamento, é imprescindível para garantir a segurança da estrutura.

2.3.2 Consumo de Cimento

Por ser uma propriedade importante, diretamente relacionada à resistência, ao custo e à durabilidade dos concretos, muitas vezes o consumo de cimento de um dado traço precisa ser explicitado. Esse valor pode ser determinado experimentalmente ou por meio de gráficos e tabelas de dosagem, como demonstrado na seção 2.3.1.

Segundo Tutikian e Helene (2011) o consumo de cimento de um traço já definido também pode ser calculado pelo método IBRACON. Esse método baseia-se em conceitos teóricos de maneira analítica, não dispensando a necessidade

de um estudo experimental em laboratório. Assim, o consumo de cimento por m³ pode ser calculado mediante a equação (10):

$$C = \frac{1000}{\frac{1}{\gamma_c} + \frac{A}{\gamma_a} + \frac{B}{\gamma_p} + x} \quad (10)$$

onde:

- C é o consumo de cimento (kg/m³)
- γ_c é a massa específica seca do cimento (kg/L);
- γ_a é a massa específica seca dos agregados miúdos (kg/L);
- γ_b é a massa específica seca dos agregados graúdos (kg/L);
- A é o traço do agregado miúdo expresso em massa;
- B é o traço do agregado graúdo expresso em massa;
- x é o fator água/cimento.

Após o cálculo do consumo de cimento, os outros materiais podem ser calculados com base no traço. Por exemplo, se em um dado traço 1:2:3:0,5 o consumo de cimento é 300 kg/m³, o consumo de areia será 600 kg/m³, de brita, 900 kg/m³ e de água, 150 kg/m³.

2.4 O Aprendizado de Máquina (*Machine Learning*)

O Aprendizado de Máquina abrange métodos que podem detectar automaticamente padrões em um conjunto de dados e, em seguida, usar esses padrões descobertos para prever dados futuros (FLACH, 2012). Assim, as técnicas de Aprendizado de Máquina são compostas por modelos que permitem a aprendizagem autônoma com base em resultados anteriores (MURPHY, 2012).

Nesse sentido, esses algoritmos são capazes de fazer classificações ou previsões consideráveis que vão desde a identificação de *spams* ao reconhecimento facial por sistemas de segurança (VERDÉRIO, 2015). Para exemplificar, Flach (2012) relata sobre um aplicativo de código aberto que identifica e filtra *spams* do e-mail: para cada e-mail recebido, com base em uma série de testes internos com base em decisões passadas do usuário, são atribuídas pontuações ou pesos para cada um dos testes. Dessa forma, o aplicativo classifica o e-mail como *spam* ou não a partir da pontuação recebida. Quanto maior o banco de dados de decisões anteriores sobre certos e-mails serem ou não *spam*, mais treinamentos são feitos e melhores resultados o algoritmo fornecerá (FLACH, 2012).

2.4.1 Tipos de Aprendizado de Máquina

De acordo com Murphy (2012), o aprendizado de máquina é dividido em dois tipos principais: o supervisionado e o não-supervisionado. No supervisionado, o objetivo é o aprendizado de uma função de mapeamento a partir de um conjunto de dados de entradas e saídas rotuladas. Ou seja, a classe ou tipo das saídas já são conhecidas. Já na aprendizagem não supervisionada, as características não possuem rótulos, sendo fornecidos apenas os dados de entrada. O objetivo desse tipo de aprendizado é a descoberta de padrões nos conjuntos de dados, que poderiam não ser notados somente pela percepção humana (MURPHY, 2012).

Para exemplificar dos tipos de aprendizado, tem-se na Figura 7 dois tipos de formas geométricas: círculos em azul claro e retângulos em azul escuro. A partir disso, algumas características como altura, largura e cor (entradas) são extraídas pelo modelo, sendo círculo ou retângulo os únicos resultados (saídas) possíveis.

Dessa forma, essa classificação é supervisionada porque já se sabe que as saídas serão círculos ou retângulos.

Entretanto, caso o problema acima fosse composto por diversas formas geométricas, mas sem os rótulos de que essas formas são círculos ou retângulos, o algoritmo teria então que decidir como rotulá-las; se por cor, forma ou tamanho. Dessa forma, como não se sabe quais são os possíveis resultados, o problema é classificado como de aprendizagem não-supervisionada. A partir disso, com a detecção de padrões nos dados de entrada, dados futuros de saída poderão ser estimados (MURPHY, 2012) .




Figura 7 - Aprendizagem de máquina supervisionada: informações sobre altura, largura e cor são extraídas de um banco de dados, com a finalidade de detectar padrões e assim prever dados no futuro. Fonte: autor, adaptado de Murphy (2012)

De acordo com o tipo de saída, os problemas podem ser indicados como de classificação ou de regressão (MURPHY, 2012). Problemas de classificação são aqueles cujas saídas são categóricas ou nominais. Já os problemas de regressão são aqueles cujas saídas são variáveis contínuas (FLACH, 2012).

Segundo Murphy (2012), alguns exemplos de aplicações de classificação:

- Classificação de documentos e filtragem de *spam* de e-mail;
- Classificação de imagem e reconhecimento de caligrafia;
- Reconhecimento e detecção facial.

São fornecidos, também, alguns exemplos reais de aplicação de regressão (MURPHY, 2012):

- Prever a idade de um espectador assistindo a um vídeo no Youtube;
- Prever a temperatura em qualquer local dentro de um edifício usando dados meteorológicos, de horário, de sensores etc.
- Prever a resistência à compressão de concretos;

São várias as técnicas de classificação e regressão, podendo-se citar alguns exemplos: máquinas de vetores suporte (*support vector machine*, em inglês, ou SVM), árvores de decisão, redes neurais artificiais (*artificial neural networks*, em inglês, ou ANN), regressão linear, regressão logística, regressão por vetores suporte (*support vector regression*, em inglês, ou SVR), algoritmo de *boosting* (*extreme gradient boosting*, em inglês, ou XGBoost) e processo gaussiano de regressão (*gaussian process regression*, em inglês, ou GPR) etc. O presente trabalho dará enfoque nas SVR, GPR, XGBoost e ANN. Esses algoritmos foram definidos com base em um teste prévio realizado pela equipe de pesquisa com bancos de dados de concretos convencionais (PAIXÃO, PENIDO, *et al.*, 2022).

2.4.2 Máquinas de Vetores Suporte (SVM)

As SVM correspondem a uma classe de algoritmos supervisionados utilizados para a classificação de padrões e regressão de funções (VERDÉRIO, 2015). Na classificação binária, as SVM se baseiam na construção de um hiperplano como superfície de decisão (BURGES, 1998). Ainda de acordo com Burges (1998), a premissa para a construção desse hiperplano é de que as classes separadas por ele estejam o mais distante possível. Isto é, quanto maior a distância entre o ponto mais próximo de cada classe ao hiperplano definido, a margem, melhor será a generalização ou predição do algoritmo (FLACH, 2012). O hiperplano ótimo é aquele que maximiza a margem de separação (MURPHY, 2012). A Figura 8 representa graficamente os infinitos hiperplanos de separação das categorias (em verde) e o hiperplano ótimo, aquele que maximiza a margem (m) (GONÇALVES, 2015).




Figura 8 - Possíveis hiperplanos de separação (em verde) e hiperplano ótimo, maximizando a margem (m). Fonte: autor, adaptado de Gonçalves (2015)

Segundo Flach (2012) , os dados de treinamento próximos à fronteira de decisão são chamados de vetores-suportes, dando nome à técnica. Dessa forma, a fronteira de decisão de uma SVM é definida como uma combinação linear dos vetores-suportes (FLACH, 2012). A Figura 9 representa graficamente esta situação em um espaço bidimensional.




Figura 9 - A geometria de um vetor suporte em classificação binária. Os pontos circunscritos em laranja são os vetores suportes. A máquina de vetores suportes encontra o limite de decisão que maximiza a margem (m).

Fonte: autor, adaptado de Flach (2012)

As aplicações em problemas reais geralmente não seguem os exemplos mostrados anteriormente, sendo em grande maioria problemas com dados complexos e não linearmente separáveis (LIMA, 2002). Nesses casos, segundo Lima (2002), devem ser introduzidas funções capazes de fazer um mapeamento

dos dados para um espaço onde os dados possam ser linearmente separáveis. Assim, a forma de separação dos dados no espaço original pode diferir de um hiperplano. A Figura 10 ilustra um conjunto linearmente separável e outro não linearmente separável (GONÇALVES, 2015).

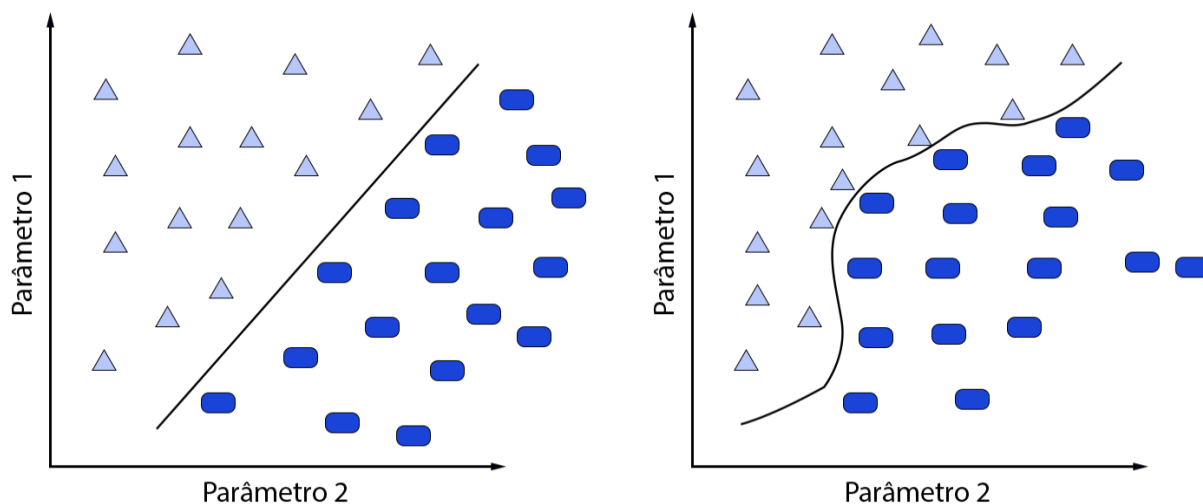


Figura 10 - Exemplos de um padrão linearmente separável (à esquerda) e outro não linearmente separável (à direita). Fonte: autor, adaptado de Gonçalves (2015)

As SVM foram originalmente concebidas para a classificação binária, mas posteriormente foram estendidas para classificação multiclasse e a regressão (MURPHY, 2012). Apesar de menos popular que as SVM, as SVR provaram ser uma ferramenta efetiva para a estimativa de funções em valores reais (AWAD e KHANNA, 2015). As SVR possuem o mesmo princípio das SVM, mas se concentram na solução de problemas de regressão. Sendo uma metodologia de aprendizagem supervisionada, as SVR utilizam-se de funções de perdas simétricas, que penalizam igualmente altas e baixas estimativas erradas (AWAD e KHANNA, 2015).

Ainda de acordo com Awad e Khanna (2015), uma das maiores vantagens da SVR é que a sua complexidade computacional não depende da dimensionalidade do espaço de entradas, isto é, da quantidade de características de entrada do problema. Além disso, ela possui uma excelente capacidade de generalização, com alta acurácia de predição.

Segundo Smola e SCHÖLKOPF (2004) as SVR podem ser descritas resumidamente da seguinte forma: para um conjunto de dados $\{(X_1, y_1), \dots, (X_l, y_l)\} \subset X \times \mathbb{R}$, onde X_i representa o espaço das variáveis de entrada, o objetivo da regressão é encontrar uma função $f(x)$ que tem no máximo um desvio ε dos valores reais y_i . Para a função linear:

$$f(x) = \langle w, x \rangle + b \text{ com } w \in X, b \in \mathbb{R} \quad (11)$$

Assim, as SVR irão transformar este problema em um problema de otimização restrita:

$$\min \frac{1}{2} \|w\|^2 \quad (12)$$

sujeita às seguintes restrições:

$$\begin{cases} y_i - \langle w, X_i \rangle - b \leq \varepsilon \\ \langle w, X_i \rangle + b - y_i \leq \varepsilon \end{cases} \quad (13)$$

O erro das previsões do modelo é tratado dentro das restrições. O modelo SVR adota uma função de perda insensível a ε , que penaliza previsões que estão mais longe que ε da saída desejada (SMOLA e SCHÖLKOPF, 2004).

Para uma explicação mais detalhada sobre este método, os autores recomendam as referências Smola e SCHÖLKOPF (2004) e Noble (2006).

Alguns exemplos de aplicações de aprendizagem de máquina na engenharia:

- Chen et al. (2019) – Avaliaram a previsão de assentamento de solo provocado por tuneladoras “Shield”: o estudo investigou a eficiência e viabilidade de seis tipos de algoritmos de aprendizagem de máquina (*back-propagation neural network, wavelet neural network, general regression neural network, extreme learning machine, SVM and random forest*). Os resultados indicaram que esses algoritmos de aprendizagem de máquina têm grande potencial em estimar o assentamento de solo provocado por tuneladoras “Shield” em comparação com o tradicional método de Regressão Linear Múltipla;
- Ying et al. (2011) – Investigaram a eficiência do monitoramento de gasodutos: o estudo investigou as técnicas de aplicação de

aprendizagem de máquina para desenvolver um sistema de detecção de danos a mudanças de pressão de ar interna a um tubo. Foram utilizados três métodos de classificação (*Adaptive Boosting*, *SVM* e um método combinado dos últimos dois). Os três classificadores obtiveram uma acurácia média de 87,7%, 92,5% e 93,5%, sendo o método combinado um classificador promissor para a detecção de danos em gasodutos.

- León et al. (2020) – Avaliaram a caracterização dos vazios de concreto asfáltico: o estudo investigou a aplicação da metodologia de segmentação de imagens por aprendizado de máquina, a partir de imagens geradas em um equipamento de microtomografia computadorizada de raios-X. Técnicas de aprendizagem de máquina como o *random forest* foram capazes de segmentar imagens microtomografadas de concreto asfáltico e fornecer valores de volume de vazios semelhantes ao método tradicional de *thresholding*. Além disso, foi possível verificar que o método de aprendizado de máquina pode ser uma técnica mais acurada e com menor intervenção humana do que a técnica de segmentação por *thresholding*.

2.4.3 Redes Neurais Artificiais (ANN)

As ANN são ferramentas de modelagem computacional que podem ser utilizadas na modelagem de problemas complexos do mundo real. As ANN são definidas como estruturas compostas por elementos simples de processamento adaptativo, interconectados, chamados neurônios. Esses neurônios são capazes de realizar cálculos paralelos massivos para a representação de conhecimento. O que torna as ANN mais atrativas é a sua notável capacidade de processamento de informações imprecisas, complexas e de características não lineares (BASHEER e HAJMEER, 2000).

As ANN são inspiradas na estrutura e funcionamento das redes neurais biológicas e constituem um dos mais importantes pilares da aprendizagem de máquina (GURNEY, 1997). As ANN são capazes de imitar a inteligência humana, de moldar relações complexas entre entradas e saídas, de extrair estruturas estatísticas e encontrar padrões nos dados (CHEN, CHALLITA, *et al.*, 2017).

Gurney (1997) relata que a habilidade de processamento das ANN é armazenada em uma unidade interna chamada peso. Esses pesos são obtidos por um processo de adaptação ou aprendizagem, a partir de um conjunto de treinamento padrão. Segundo Chen et al. (2017) as sinapses são então modeladas de tal forma que cada entrada é multiplicada por um peso, que são então somados por adição aritmética simples nos chamados nós. Assim, esse valor obtido no somatório será utilizado para gerar um valor segundo uma função de ativação, conforme a equação (14). A Figura 11 representa um modelo básico de um neurônio matemático.

$$y_k = f \left(\sum_{i=1}^n w_i N_i + b \right) \quad (14)$$

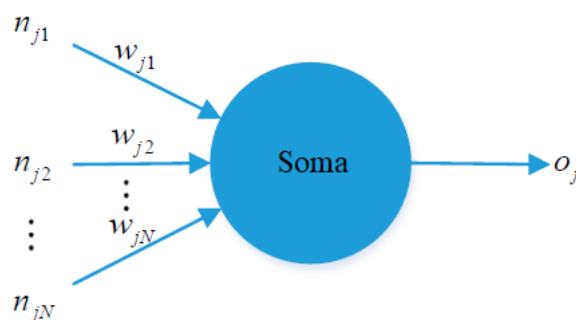


Figura 11 - Um modelo de neurônio matemático. Em que n_{jk} representa o sinal de entrada do neurônio j e w_{jk} é o peso correspondente à entrada.

Fonte: autor, adaptado de Chen et al. (2017)

As funções de ativação basicamente decidem se o neurônio será ativado ou não, e a escolha do seu tipo dependerá dos objetivos almejados (BISHOP, 2006). Bishop (2006) então elucida que as ANN são uma composição de múltiplos neurônios conectados em diferentes formas e operando com a partir de diferentes funções de ativação. De acordo com Chen et al. (2017) , os principais componentes das ANN incluem as seguintes:

- Camada de entrada: consiste em um número de neurônios usados para representar o sinal de entrada;
- Camada de saída: consiste em um número de neurônios usados para representar o sinal de saída;

- Camada oculta: consiste em um número neurônios responsáveis por fazer cálculos intermediários, imitando as operações no sistema nervoso humano;
- Matriz de pesos de entrada: representa a força de conexão entre os neurônios na camada oculta;
- Matriz de pesos de saída: representa a força de conexão entre os neurônios da camada oculta e os neurônios da camada de saída.

A Figura 12 ilustra uma das formas mais simples de ANN, as Redes Alimentadas Adiante (*Feed-forward Neural Network*) (CHEN, CHALLITA, *et al.*, 2017) . A função que descreve a Rede Neural mencionada pode ser entendida na Equação (15). Tem -se que y_j é responsável por fornecer o a saída de cada neurônio de acordo com a respectiva camada l (FINOTTI, CURY e BARBOSA, 2019).




Figura 12 - Representação de uma ANN por alimentação adiante (Feed-Forward). Fonte: autor, adaptado de Chen et al. (2017)

$$y_j = f \left(\sum_{i=1}^n w_{ij}^{(l-1)} N_i^{(l-1)} + b^{(l-1)} \right), \quad \text{para } j = 1, \dots, k^l \quad (15)$$

As ANN têm sido utilizadas em uma variedade de aplicações que variam de modelagem, classificação, reconhecimento de padrões e análise multivariada de dados (BASHEER e HAJMEER, 2000).

Algumas aplicações com ANN:

- Lorenzi et al. (2011) – O artigo teve como objetivo estudar o potencial das ANN em estimar a resistência à compressão do concreto, a partir de um banco de dados de traços. Os resultados demonstraram que as ANN podem ser utilizadas para gerar modelos robustos e flexíveis para a estimativa da resistência à compressão, alcançando resultados de R^2 da ordem de 0,90;
- Martins (2011) – A dissertação estudou a aplicação das ANN com o objetivo de estimar a profundidade de carbonatação do concreto armado. Foram utilizadas ANN do tipo *perceptron* multicamadas com o algoritmo de *backpropagation*. Os resultados permitiram avaliar que as ANN são importantes ferramentas para a avaliação da profundidade de carbonatação do concreto armado, obtendo correlações da ordem de 0,9959 e MSE de 0,0083;
- Cavalcanti (2010) – A dissertação buscou explorar a possibilidade de interpretar os ensaios não-destrutivos de ultrassom a partir das ANN, com a finalidade de se obter a resistência à compressão do concreto. Os resultados demonstraram que a simulação com ANN, combinadas com os ensaios de ultrassom, possuem grande potencial para estimar a resistência à compressão do concreto. Com o estudo foi possível alcançar correlações da ordem de 0,8746 e erro de 0,1006.

2.4.4 Algoritmo de *Boosting* (XGBoost)

De acordo com Schapire (1999), técnicas de *Boosting* são métodos de *Ensemble* que buscam alavancar a precisão de um algoritmo de aprendizagem. O XGBoost é baseado no algoritmo de árvores de decisão.

A árvores de decisão é um modelo de predição da área de aprendizagem de máquina, cujo algoritmo classificador é expresso como uma partição repetitiva do espaço das instâncias (ROKACH e MAIMON, 2015). De acordo com Rokach e Mainmon (2015), as árvores de decisão podem ser utilizadas tanto para a

classificação (árvores de classificação) quanto para regressão (árvores de regressão), caso a variável-alvo seja categórica ou numérica, respectivamente.

A estrutura de uma árvore de decisão é constituída por nós. No topo, encontra-se o nó “raiz” da árvore, que é um nó que não possui bordas de entradas. A partir deste partem nós que possuem bordas de entrada e de saída, chamados de nós de “decisão” e também os nós folhas, que podem corresponder a uma classe ou valor, não possuindo bordas de saídas (MONARD e BARANAUSKAS, 2003). A Figura 13 ilustra a estrutura de uma árvore de decisão.

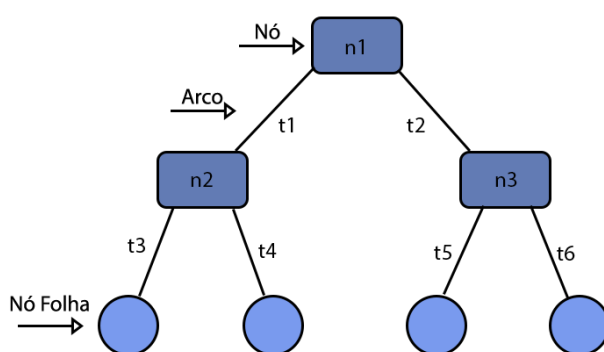


Figura 13 – Estrutura de uma Árvore de Decisão. Fonte: autor, adaptado de Garcia (2003)

Dessa forma, cada ramificação representa uma escolha entre um número de opções, e cada nó uma decisão. Assim, uma árvore de decisão é capaz de solucionar problemas complexos, dividindo-os em subproblemas mais fáceis. O resultado é dado pela resolução e combinação desses subproblemas (YASA e ETEMAD-SHAHIDI, 2014).

Já os métodos *Ensemble* são algoritmos de aprendizagem que constroem e combinam um agrupamento de classificadores. A partir dessa combinação, novas observações são obtidas a partir da média ponderada da predição desses classificadores (DIETTERICH, 2000).

A alavancagem na precisão proporcionada pelo XGBoost tem como base a transformação de preditores fracos (*weak learners*) em um preditor forte (*strong learner*). Joshi, Agarwal e Kumar (2002) mencionam que, dado um conjunto de dados rotulados, um preditor fraco é aquele que produz um classificador

ligeiramente mais preciso do que a classificação aleatória. Já um preditor forte é aquele que apresenta uma precisão arbitrariamente boa.

O XGBoost aplicado em árvores de decisão é altamente eficaz e vastamente utilizado nos métodos de aprendizagem (CHEN e GUESTRIN, 2016). Com base nisso, Chen e Guesterin (2016) propuseram um algoritmo inovador para dados esparsos, que é capaz de produzir resultados de ponta em diversas em aplicações. É possível inferir sobre a capacidade desse algoritmo mediante os desafios apresentados pelo site de competição de aprendizado de máquinas *Kaggle's*. Em 2015, dentre as 29 soluções vencedoras, 17 soluções fizeram uso do *XGBoost*, sendo que em oito delas o *XGBoost* foi utilizado de maneira exclusiva (KAGGLE, 2015; CHEN e GUESTRIN, 2016).

De acordo com Chen e Guesterin (2016), o sistema pode ser até dez vezes mais rápido (assumindo uma única máquina) do que outras soluções existentes. Essa alta escalabilidade deve-se a diversas otimizações algorítmicas:

- Algoritmo de aprendizagem de árvore capaz de lidar com dados esparsos;
- Esboço de quantil ponderado que permite o manuseio de pesos das instâncias na aprendizagem de árvore aproximada;
- Exploração de cálculos fora do núcleo, o que permite o processo de centenas de milhões de exemplos em um único desktop;
- A combinação de todas essas técnicas, produzindo um sistema escalável de ponta a ponta capaz de tratar uma maior quantidade de dados, com o menor uso de recursos.

Para um determinado conjunto de dados com n instâncias e m características $D = \{(x_i, y_i)\} (|D| = n, x_i \in \mathbb{R}^m, y_i \in \mathbb{R})$, um modelo de conjunto de árvores utiliza K funções aditivas para prever as saídas, conforme a equação (16):

$$\hat{y}_i = \phi(X_i) = \sum_{k=1}^K f_k(X_i), f_k \in F \quad (16)$$

onde F é o espaço das árvores de regressão, também conhecidas como *Classification and Regression Trees* (CART), conforme a função (17):

$$F = \{f(x) = w_{q(x)}\} (q : \mathbb{R}^m \rightarrow T, w \in \mathbb{R}^T) \quad (17)$$

Em que

- q representa a estrutura de cada árvore;
- T é o número de folhas em cada árvore;

Dessa forma, cada f_k corresponde a uma estrutura de árvore independente (q) com os pesos de folhas iguais a w . Assim, diferentemente das árvores de decisão, cada árvore de regressão possui uma pontuação de valor contínuo em cada folha, com w_i correspondendo ao peso da i -ésima folha.

De acordo com Chen e Guesterin (2016) para o aprendizado do conjunto de funções usadas no modelo é necessário minimizar a função (18):

$$L(\emptyset) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (18)$$

onde:

- l é uma função de perda convexa diferenciável que mede a diferença entre o valor predito (\hat{y}_i) e o valor alvo (y_i);
- Ω é um termo que penaliza a complexidade do modelo. Essa regularização adicional auxilia a suavizar os pesos finais com a finalidade de evitar o sobreajuste (*overfitting*).

Assim, Ω é dado pela seguinte equação (19):

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (19)$$

É importante mencionar que o XGBoost aplicado às árvores de decisão possui funções que não podem ser otimizadas simplesmente utilizando-se os métodos tradicionais no espaço euclidiano. Logo, o modelo é treinado de maneira aditiva, sendo obtida a seguinte equação simplificada (20):

$$\tilde{L}^{(t)} = \sum_{i=1}^n [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (20)$$

Definindo-se $I_j = \{i | q(x_i) = j\}$ como o conjunto de instâncias na folha j , tem-se pela equação (21):

$$\tilde{L}^{(t)} = \sum_{j=1}^T [(\sum_{i \in I_j} g_i) w_j + \frac{1}{2} (\sum_{i \in I_j} h_i + \lambda) w_j^2] + \gamma T \quad (21)$$

Desse modo, para uma estrutura fixa $q(x)$, é possível calcular o peso ótimo da folha w_j^* da folha j pela equação (22):

$$w_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (22)$$

Como também o valor ótimo correspondente, obtido pela equação (23):

$$\tilde{L}^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (23)$$

Já que é habitualmente impossível enumerar todas as estruturas de árvores possíveis, é utilizado um “algoritmo guloso” (*greedy algorithm*). Este algoritmo parte de uma única folha e segue adicionando ramos de maneira iterativa. Logo, assumindo-se que I_L e I_R são, respectivamente, os conjuntos de instâncias à esquerda e à direita do nó após a divisão. A equação (24) geralmente é utilizada para a avaliação dos candidatos divididos:

$$L_{div} = \frac{1}{2} \left[\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma \quad (24)$$

Alguns exemplos de aplicações de *XGBoost* na Engenharia Civil:

- Parsa, Movahedi, et al. (2020) – Utilizaram o modelo de *XGBoost* com a finalidade de detectar ocorrências de acidentes em estradas. Para tanto, foi utilizado um conjunto de dados em tempo real, composto por tráfego, características meteorológicas, uso do solo etc. Os resultados demonstraram que o *XGBoost* pôde detectar acidentes de maneira robusta com uma precisão e taxa de falsos alarmes de 99% e 0,16%, respectivamente.
- Dong, Huang, et al. (2020) – Buscaram monitorar a integridade estrutural de infraestruturas de pontes e edifícios com a utilização do algoritmo *XGBoost*. Para a detecção de durabilidade do concreto foi empregado o método de medição de resistividade elétrica. O algoritmo foi treinado como uma base de dados constituída por 800 instâncias e 16 características de entrada. Os resultados demonstraram que o modelo foi capaz de atingir um desempenho satisfatório, com ajustes de regressão de 0,991 e 0,943.
- Osman, Ahmed, et al. (2021) – Propuseram um modelo de previsão de níveis de água subterrânea por meio da avaliação de três métodos de aprendizagem de máquina: *XGBoost*, *ANN* e *SVR*. Os modelos foram treinados por meio de uma base de dados composta por 11 meses de medições de precipitação, temperatura e evaporação. O melhor resultado foi obtido pelo *XGBoost*, com um ajuste de regressão de 0,92, enquanto a *ANN* e o *SVR* obtiveram, respectivamente, 0,57 e 0,88.

2.4.5 Processo Gaussiano de Regressão (GPR)

O GPR funciona sob a estrutura de regressão probabilística, que toma como entrada um conjunto de dados de treinamento $D = \{(y_n, x_n), n = 1, \dots, N\}$ de N pares da entrada vetorial $x_n \in \mathbb{R}^L$ e como, saída, um escalar y_n do tipo ruído (valores aleatórios extraídos de uma distribuição probabilística), e constrói um modelo que generaliza bem a distribuição de saídas. Tem-se que o ruído nos

modelos de saída é devido a fatores externos à x , tais como erros de truncamento ou de observações (WAN e SAPSIS, 2017).

De acordo com Williams e Rasmussen (2006), o GPR é uma coleção de variáveis aleatórias, ou seja, qualquer número finito nos quais haja uma distribuição gaussiana conjunta. Dessa forma, uma das maiores vantagens do GPR é que ele pode ser determinado pela média $m(x)$ e covariância $k(x, x')$ por meio da seguinte função (25):

$$f(x) \sim GP(m(x), k(x, x')) \quad (25)$$

Desse modo, é possível definir a função média $m(x)$ e covariância $k(x, x')$ por meio das equações (26) e (27), onde $E[f(x)]$ é a esperança matemática. É importante ressaltar que, para simplificação, a função média é considerada igual a zero (WILLIAMS e RASMUSSEN, 2006) .

$$m(x) = E[f(x)] \quad (26)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (27)$$

Segundo Wan e Sapsis (2017), a função de covariância possui um número de parâmetros livres, chamados hiperparâmetros. Esses são responsáveis por definir a distribuição anterior em $f(x)$. Para tanto, a função de variância mais utilizada no GPR é a de covariância exponencial quadrada, obtida pela equação (28):

$$k(x, x') = \theta_1 \exp\left(-\frac{\|x - x'\|^2}{2\theta_2}\right) \quad (28)$$

onde:

- $\| \cdot \|$ é a norma definida no espaço de entrada;
- θ_1 é um hiperparâmetro que especifica a covariância máxima permitida;
- θ_2 é um parâmetro estritamente positivo que define a taxa de declínio na correlação quando os pontos começam a se distanciar uns dos outros.

Alguns exemplos de aplicações de GPR na Engenharia Civil:

- Li, He, et al. (2017) - O trabalho teve como objetivo criar um modelo para prever a entrada de água durante a construção de túneis. A pesquisa se baseou em três modelos de aprendizado de máquinas: SVM, ANN e GPR. O modelo de GPR obteve um coeficiente de determinação (R^2) de 0,9397, sendo superior ao obtido pelas SVM (0,9134) e pelas ANN (0,8331). É importante mencionar que os resultados obtidos pelo modelo de GPR indicaram boa concordância com os resultados obtidos em campo;
- (MOMENI, DOWLATSHAHI, *et al.*, 2020) - A pesquisa teve como objetivo a criação de um modelo baseado no GPR a fim de estimar a capacidade de carga de estacas de fundação. Além disso, a fim de comparar os desempenhos, também foi utilizado o modelo de ANN baseada em algoritmo genético. Os resultados demonstraram que o modelo de GPR é suficientemente capaz de estimar a capacidade de carga de estacas, além de alcançar um resultado superior ao modelo de ANN, obtendo, respectivamente, R^2 de 0,84 e R^2 de 0,81.

2.5 Aplicações de aprendizagem de máquina em concretos

2.5.1 Concretos Convencionais

Alguns autores também já buscaram estimar a resistência à compressão de concretos com a utilização de técnicas de aprendizagem de máquina. Abaixo seguem alguns exemplos das técnicas utilizadas e os seus principais resultados alcançados:

- Bonifácio et al. (2019) – Investigaram a aplicação da SVR e do método de elementos finitos (MEF) a fim de prever as propriedades mecânicas do concreto. O estudo comparou as técnicas de SVR e MEF com a finalidade de estimar a resistência à compressão e o módulo de elasticidade em concretos de agregados leves. Os resultados indicaram que tanto as técnicas de aprendizagem de máquina (SVR), quanto as técnicas de modelos baseados na mecânica clássica (MEF)

são viáveis para estimar a resistência à compressão e o módulo de elasticidade com pequenos desvios. No entanto, as SVR apresentaram um desempenho ligeiramente melhor que o MEF, com um desvio padrão médio de 5,46% para a resistência à compressão e 2,48% para o módulo de elasticidades, enquanto o MEF apresentou desvios médios de 6,55% para a resistência à compressão e 2,91% para o módulo de elasticidade;

- Hoang, Pham, et al. (2016) – A pesquisa buscou realizar um estudo comparativo sobre os resultados da estimativa da resistência à compressão de concretos de alta performance. Para isso, foram utilizados três modelos de aprendizado de máquinas: SVM por mínimos quadrados, ANN e GPR. Os resultados demonstraram que o GPR realizou um bom mapeamento entre as entradas e a saída, obtendo um R^2 de 0,90, superior aos demais métodos - ANN (0,89) e SVM com mínimos quadrados (0,85);
- Chou, Tsai et al. (2014) – Avaliaram o aprendizado de máquinas em simulações da resistência à compressão de concretos de alto desempenho. O estudo fez o uso de técnicas avançadas em aprendizado de máquinas, incluindo SVM, MLP, árvores de classificação e regressão e regressão linear. Os resultados demonstraram que os modelos foram suficientemente capazes de estimar a resistência à compressão dos concretos de alto desempenho, indicando dois melhores modelos simples para o banco de dados. As SVM alcançaram desvios entre 1,31 e 3,75 MPa; já o MLP entre 4,00 e 4,28 MPa. O estudo também sugeriu que o uso dessas técnicas em conjunto pode atingir medidas de desempenho ainda melhores.
- Dao, Adeli et al. (2020) – Buscaram avaliar a acurácia das ANN e do GPR para o conjunto de dados montado por Yeh (1998), um dos mais utilizados no mundo, a partir de uma simulação de Monte Carlo. Um dos objetivos desse trabalho era encontrar boas previsões para resistência à compressão dos concretos desse banco de dados. O conjunto de dados foi submetido a uma separação simples em treino (70%) e teste (30%). Os autores obtiveram um R^2 de 0,89 com o GPR

e indicaram que esses algoritmos podem contribuir para o processo dosagem de concretos.

- Paixão, Penido et al. (2022) – o artigo buscou comparar diferentes técnicas de aprendizado de máquinas para estimar a resistência de concretos convencionais. Para isso, foi utilizado um banco de dados da literatura como entrada para quatro modelos: ANN, XGBoost, SVR e GPR. Além disso, a qualidade das estimativas realizadas pelos modelos foi avaliada por meio da validação cruzada ($k = 10$) e de três métricas estatísticas: R^2 , MAE e RMSE. Nesta primeira etapa os modelos obtiveram bons resultados com MAE entre 1,96-2,26 MPa e R^2 variando de 0,79 a 0,83. Na segunda parte do trabalho os autores realizaram a validação dos modelos com um banco de dados externo. No entanto, os resultados para essa etapa caíram drasticamente, com MAE subindo para 3,03-4,03 MPa e R^2 diminuindo para 0,36-0,59. Além disso, foi possível inferir de que os modelos de ANN e GPR obtiveram as melhores estimativas, enquanto o modelo de SVR obteve as piores. Dessa forma, o artigo mostrou que as ferramentas de aprendizado de máquinas são técnicas promissoras estimar a resistência à compressão do concreto.

É importante mencionar que em todos os artigos citados acima foi possível obter bons desempenhos para a predição de propriedades do concreto. Além disso, destaca-se que múltiplas técnicas e metodologias foram utilizadas para esse fim. Logo, até o momento não é possível afirmar qual técnica ou metodologia é a mais eficaz, pois eles irão variar de acordo com a finalidade, características do banco de dados, etc. No entanto, isso não exclui a atenção necessária para utilização de técnicas condizentes e de análises para se evitar resultados tendenciosos.

2.5.2 Concretos de Escória de Aciaria

Devido à sua eficácia e praticidade de aplicação, as técnicas de aprendizado de máquina também vêm sendo adotadas para a estimativa de propriedades de concretos não-convencionais, como os concretos de escória de aciaria. Abaixo

seguem alguns exemplos das técnicas utilizadas nesses concretos e os seus principais resultados alcançados:

- Bian et al. (2021) – Os autores utilizaram as técnicas de aprendizado de máquinas para avaliar a resistência à compressão e a taxa de expansão de concretos com 100% de substituição dos agregados por escória de aciaria. O modelo utilizou técnicas de algoritmos genéticos e ANN por retropropagação. Para tanto, os autores produziram 25 corpos de prova cúbicos, de 100 mm de lado com a finalidade de avaliar a resistência à compressão e 25 corpos de prova cilíndricos, de 100x100x300 mm para avaliar a taxa de expansão do concreto. Os resultados obtidos tiveram desvios estimados na ordem de 2,5-5% (0,9 – 2,2 MPa), tendo sido classificados como boas estimativas.
- Gupta e Sachdeva (2021) – Investigaram a estimativa da resistência à compressão e à flexão de concretos de escória de aciaria para pavimentação. Fizeram o uso das ANN diretas. Os corpos de prova examinados consistiam de 0, 10, 15, 20 e 25% de escória obtida pelo processo de descarbonetação argônio-oxigênio. O modelo alcançou resultados com erros na ordem de 0,05-0,15 MPa, demonstrando a eficácia do método;
- Lam, Nguyen e Le (2020) – Avaliaram a estimativa da resistência à compressão de concretos compactos a rolo contendo escória de aciaria e cinzas volantes. Foram estabelecidos três modelos analíticos: análise de regressão múltipla, ANN e lógica difusa. O conjunto de dados foi submetido a uma separação simples em treino (70%) e teste (30%). Com a finalidade de estimar a resistência à compressão desses concretos, os modelos de Análise de Regressão Múltipla, ANN e FL apresentaram, respectivamente, os seguintes resultados de R^2 : 0,79; 0,92 e 0,83. Os resultados sugeriram que, para a estimativa da resistência à compressão desses concretos, o modelo de Análise de Regressão Múltipla é menos seguro do que o modelo de ANN. Já o modelo FL possui resultados tão bons quanto o modelo de ANN. Além disso, a utilização de funções de associação triangular no modelo FL leva

a resultados precisos com apenas três variáveis (cinza volante, agregado de escória de aciaria e idade).

Em todos os artigos citados acima foi possível obter bons desempenhos para a estimativa à resistência à compressão de concretos de escória de aciaria. Ademais, por conta das diversas técnicas e metodologias utilizadas, ainda não é possível afirmar quais são mais eficazes para o problema proposto, pois cada modelo irá se adaptar de uma forma para diferentes bancos de dados e diferentes tipos de concreto. No entanto, algumas considerações podem ser feitas sobre as metodologias desses artigos.

No artigo de Bian et al. (2021), os autores treinaram os seus modelos por meio de um banco de dados com apenas 25 corpos de provas moldados por eles mesmos. Já no artigo de Lam, Nguyen e Le (2020), os autores treinaram os seus modelos por meio de um banco de dados com 75 corpos de provas também moldados por eles mesmos. É importante ter em mente que esses modelos até podem ser eficazes para estimar a resistência de concretos produzidos pelo próprio laboratório. Entretanto, treinar os modelos por meio de uma fonte tão homogênea pode comprometer a sua capacidade de generalização para concretos de outras origens, devido à falta de representatividade do banco de dados (FEITOSA, SANTOS, *et al.*, 2017).

Já no trabalho de Gupta e Sachdeva (2021) e Lam, Nguyen e Le (2020), os autores treinaram os modelos separando os dados de maneira simples, entre treino (70%) e teste (30%), sem utilizar a técnica de validação cruzada. Com isso, essa divisão simples pode gerar resultados tendenciosos, dependendo de quais instâncias específicas são agrupadas em qual grupo (BLOCKEEL e STRUYF, 2002). Além disso, em nenhum desses artigos houve a validação com um banco de dados externo ou experimental, o que não permite inferir sobre a capacidade de generalização desses modelos.

3 METODOLOGIA

3.1 Visão geral da metodologia

Este trabalho visa construir modelos baseados em técnicas de aprendizagem de máquina a fim de estimar a resistência à compressão de concretos de escória de aciaria. A Figura 14 ilustra a visão geral da metodologia. O primeiro passo foi levantar dados de traços e de resistências à compressão de concretos de escória de aciaria na literatura. Esse banco de dados foi pré-processado para que se efetuasse a normalização dos parâmetros considerados (ex. definição de traço em proporção foi convertida para consumo de cada material, de acordo com as equações da seção 2.3.2). A partir deste banco de dados padronizado, quatro modelos supervisionados de aprendizagem de máquina foram desenvolvidos com a finalidade de relacionar os dados de entrada (*inputs*) aos dados de saída (*target*). Dessa forma, para este trabalho, os componentes do traço do concreto são os dados de entrada e, a resistência à compressão [MPa], o dado de saída.

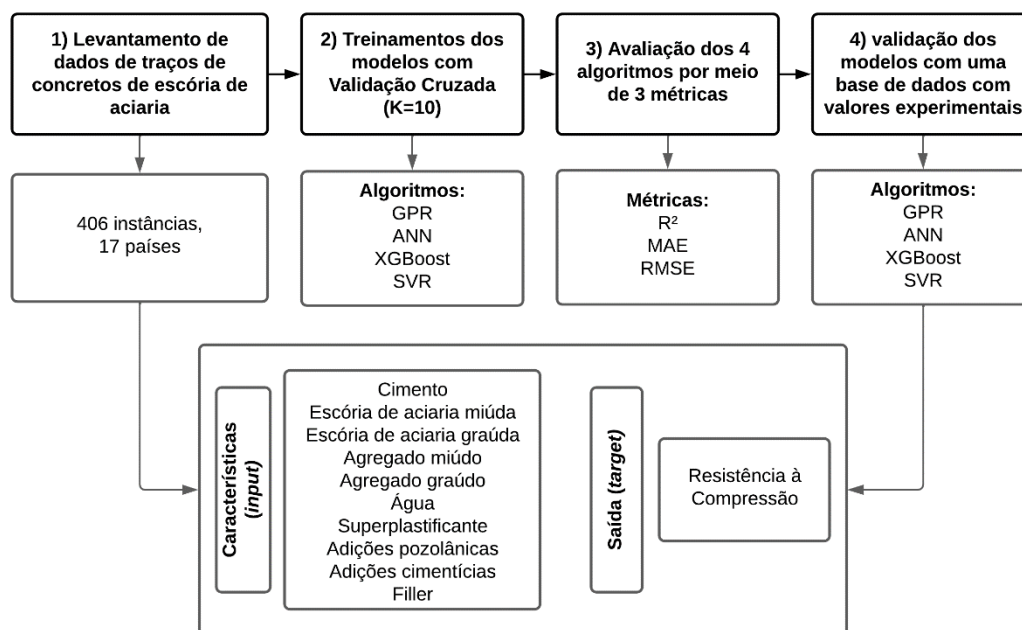


Figura 14 - Visão Geral da Metodologia. Fonte: autor

Na sequência, foi avaliada a qualidade das estimativas realizadas pelos modelos por meio da técnica de validação cruzada e três métricas estatísticas: coeficiente de determinação (R^2), erro absoluto médio (*mean absolute error*, em

inglês, ou MAE) e erro quadrático médio (*root mean squared error*, em inglês, ou RMSE). Essas técnicas serão melhor descritas mais à frente. Em seguida, também foi realizada a validação com valores experimentais provenientes de um banco de dados externo. Essa validação foi utilizada para saber se o modelo realmente foi capaz de estimar valores para qualquer traço desenvolvido no mundo, ou se ele é válido somente para os dados do seu próprio conjunto treinado.

3.2 Construção do banco de dados

3.2.1 Levantamento sistemático de referências

Inicialmente foram levantados dados de traços e de resistências de concreto de escória existentes na literatura. As buscas foram feitas em bases de dados científicos como o Google Acadêmico, Scopus e Web of Science. Encontram-se na Tabela 4 os dados utilizados para essa revisão.

Tabela 4 - Dados do levantamento de literatura. Fonte: autor

Base de dados	Palavras-chave	Quantidade	Intervalo de Buscas
Google Acadêmico	concreto escória de aciaria	Aproximadamente 1.190 resultados	01/03/2021 - 14/03/2021
Google Acadêmico	steel slag and concrete and compressive strength	Aproximadamente 50.400 resultados	
Scopus	steel slag and concrete and compressive strength	714 resultados	
Scopus	steelmaking slag and concrete and compressive strength	75 resultados	
Web of Science	steel slag and concrete and compressive strength	740 resultados	
Web of Science	steelmaking slag and concrete and compressive strength	33 resultados	

Foram considerados artigos publicados em periódicos, teses e dissertações, em português e em inglês. Após esse levantamento inicial, as referências foram filtradas para somente incluir trabalhos que usavam a escória de aciaria como agregado no concreto e que possuíam o traço e a resistência à compressão desses concretos. Dessa primeira seleção resultaram 118 trabalhos (excluindo as duplicatas).

Como o presente trabalho focou em concretos convencionais para edificações, numa segunda revisão foram descartados temas relativos a: escória de aciaria como adição mineral, concretos de escória de aciaria para pavimentação viária, escória de aciaria em concretos compactados a rolo etc. Dessa forma, a lista de trabalhos foi reduzida a 83.

Posteriormente, foi realizada uma análise minuciosa nos textos. Ainda que muitos trabalhos fossem aderentes ao tema, eles possuíam informações incompletas, como a ausência do tamanho do agregado utilizado, de dados completos sobre o traço ou das dimensões do corpo de prova. É importante mencionar que antes da eliminação desses artigos, houve uma tentativa de contatar os autores através dos endereços de e-mail dos autores correspondentes.

Dessa forma, após essa análise minuciosa e o contato com diversos autores, foi possível aproveitar 33 arquivos para o levantamento do banco de dados. Em seguida, foram criadas tabelas de quantitativos, indicando todos os componentes utilizados no traço do concreto. O banco de dados completo está disponibilizado nos apêndices deste trabalho e no link <https://github.com/cidengcnpq>, caso outros pesquisadores também queiram testar os modelos. O autor solicita que, caso o banco de dados seja utilizado, que se cite o artigo “Predicting the compressive strength of steelmaking slag concrete with machine learning - considerations on developing a mix design tool”.

3.2.2 Padronização dos dados

Cada trabalho levantado possui uma forma de expor os resultados e utilizam unidades de medida típicas do costume e das normas empregadas em cada região. Por conta disso, foram feitas diversas conversões de unidades das informações obtidas, bem como a transformação de dados em traço para dados em consumo (kg/m^3). Essas conversões foram realizadas a fim de possibilitar uma melhor convergência e padronização dos dados. Os componentes finais e seus quantitativos foram classificados da seguinte forma:

- Cimento [kg/m^3];
- Escória de aciaria na fração miúda [kg/m^3];

- Escória de aciaria na fração graúda [kg/m³];
- Agregado miúdo [kg/m³];
- Agregado graúdo [kg/m³];
- Água de amassamento [kg/m³];
- Aditivo superplastificante [%];
- Adições pozolânicas [kg/m³];
- Adições cimentícias [kg/m³];
- Filler [kg/m³];
- Idade [dias];
- Resistência à compressão [MPa];

A base de dados completa, criada a partir dos 33 arquivos, possui um total de 406 instâncias (observações), provenientes de 17 países, de pesquisas realizadas entre 1997 e 2021. Essa grande diversidade também está presente nos corpos de prova ensaiados, sendo de tamanhos variados, nas formas cúbica ou cilíndrica.

Por conta disso, houve a necessidade de se realizar a padronização dos corpos de prova, sendo escolhida a forma cilíndrica de 10x20 cm, utilizada pela NBR 5739 (ABNT, 2018) . Essa conversão dos formatos e tamanho dos corpos de prova foi realizada por meio de fatores de correção apresentados por Yi, Yang e Choi (2006) para concretos convencionais de agregados naturais. Esses fatores de correção são apresentados na Tabela 5.

Tabela 5 - Fatores de correção com tamanho e formas para concretos de resistência normal. Fonte: autor, adaptado de Yi et al. (2006)

Fatores de Correção para Cilindros	d (mm)	Cilindro	Cubo	Prisma	Cubo, paralelo	Prisma, paralelo
Cilindro (100), CF = 1,0	50	1,05	1,34	1,14	1,47	1,13
	100	1,00	1,18	1,01	1,27	1,00
	150	0,97	1,10	0,94	1,16	0,93
	200	0,96	1,05	0,90	1,09	0,88
Cilindro (150), CF = 1,0	50	1,07	1,38	1,17	1,51	1,16
	100	1,03	1,22	1,04	1,30	1,02
	150	1,00	1,13	0,97	1,19	0,95
	200	0,98	1,07	0,92	1,12	0,90

3.2.3 Pré-processamento da base de dados

Após a padronização das formas e tamanhos dos corpos de prova, o conjunto de dados completo passou a contemplar concretos de escória de aciaria com resistência de 4 a 94 MPa. A partir disso, a Tabela 6 fornece uma breve descrição dessa base de dados, que pode ser encontrada na íntegra nos apêndices. É importante mencionar que as características (*features*) demonstraram uma boa variabilidade dentro do que é esperado para concretos convencionais e de alta resistência.

Tabela 6 - Descrição da base de dados completa. Fonte: autor

Característica	Unidade	Valor mínimo	Valor máximo	Média	Desvio Padrão
Cimento	kg/m ³	54,5	678,2	392,5	90,0
Escória de aciaria na fração miúda	kg/m ³	0,0	1919,0	326,8	427,5
Escória de aciaria na fração graúda	kg/m ³	0,0	2100,0	767,5	563,8
Agregado miúdo	kg/m ³	0,0	1400,0	435,3	349,4
Agregado graúdo	kg/m ³	0,0	1426,3	445,7	477,0
Água de amassamento	kg/m ³	111,8	312,0	180,0	39,5
Aditivo superplastificante	%	0,0	3,6	0,6	0,8
Adições pozolânicas	kg/m ³	0,0	87,1	3,9	11,1
Adições cimentícias	kg/m ³	0,0	435,9	3,2	32,1
Filler	kg/m ³	0,0	815,0	8,3	80,6
Idade	dias	1,0	360,0	38,1	47,6
Resistência à compressão	MPa	4,5	93,9	40,2	20,8

Após todas as conversões necessárias, realizou-se o pré-processamento dos dados para tratar de problemas de escala e análise de dados discrepantes (*outliers*). Assim, o pré-processamento teve como finalidade o ajuste de particularidades que pudessem impactar diretamente no desempenho dos modelos.

A Tabela 6 mostra que as idades referentes às resistências obtidas variavam entre 1 e 360 dias (relativas a um mesmo traço de concreto, para o qual os autores desejavam acompanhar a evolução da resistência). Entretanto, como a maior parte nas necessidades de dosagem foca na resistência à compressão aos 28 dias, com o objetivo de evitar vieses ocasionados por esse parâmetro, foram filtrados apenas os dados referentes aos corpos de prova que foram rompidos nessa idade. Com base nisso, o novo banco de dados para 28 dias

sofreu uma redução de 64%, ou seja, de 406 para 146 instâncias (observações). Após essa nova configuração, o conjunto de dados para 28 dias passou a contemplar concretos de escória de aciaria com resistência de 9 a 92 MPa e a característica “idade” foi removida, pois não era mais necessária. A Tabela 7 mostra a descrição dessa base de dados final, que foi a utilizada para as etapas seguintes.

Tabela 7 - Descrição da base de dados com resistência somente aos 28 dias. Fonte: autor

Característica	Unidade	Valor mínimo	Valor máximo	Média	Desvio Padrão
Cimento	kg/m ³	54,5	678,2	393,4	94,4
Escória de aciaria na fração miúda	kg/m ³	0,0	1919,0	312,0	427,0
Escória de aciaria na fração graúda	kg/m ³	0,0	2100,0	791,5	533,2
Agregado miúdo	kg/m ³	0,0	1400,0	462,3	370,7
Agregado graúdo	kg/m ³	0,0	1426,3	387,5	463,7
Água de amassamento	kg/m ³	111,8	312,0	186,8	34,1
Aditivo superplastificante	%	0,0	3,6	0,5	0,8
Adições pozolânicas	kg/m ³	0,0	60,0	2,0	8,0
Adições cimentícias	kg/m ³	0,0	435,9	3,7	36,9
Filler	kg/m ³	0,0	815,0	11,5	94,8
Resistência à compressão	MPa	9,4	92,2	37,2	18,1

3.3 Construção dos Modelos

3.3.1 Algoritmos adotados e treinamento

Em virtude da alta complexidade e correlação entre os componentes do concreto, modelos de regressão não-linear são convencionalmente adotados para esse tipo de problema (CHOU, TSAI, *et al.*, 2014; ATICI, 2010; BHANJA e SENGUPTA, 2002). Diversos tipos de algoritmos poderiam ter sido usados na resolução deste trabalho, no entanto, houve uma pré-seleção inicial com a utilização de um banco de dados de concretos convencionais, que foi publicada separadamente (PAIXÃO, PENIDO, *et al.*, 2022). Assim, os modelos selecionados como mais promissores para esse trabalho foram: regressão por vetores suporte (*support vector regression*, em inglês, ou SVR), redes neurais artificiais (*artificial neural networks*, em inglês, ou ANN), *extreme gradient boost* (XGBoost) e processo gaussiano de regressão (*gaussian process regression*, em inglês, ou GPR).

Todas as simulações deste estudo foram desenvolvidas utilizando um computador com processador Intel Core i7-6500U com 16 Gb de memória RAM. A implementação dos algoritmos foi realizada por meio do software Python 3.8.6 e com a utilização das bibliotecas *pandas*, *scikit-learn*, *XGBoost* e *TensorFlow*.

Com a finalidade de realizar o ajuste dos hiperparâmetros para o modelo SVR, os autores variaram o coeficiente de kernel (também conhecido como “gamma”) e o parâmetro de regularização “C” aleatoriamente de 10^{-2} a 10^3 . Os melhores resultados foram alcançados com “gamma” e “C” como 0,01 e 205,66, respectivamente. Para uma explicação mais detalhada sobre este método, os autores recomendam a referência (SMOLA e SCHÖLKOPF, 2004).

Já no modelo das ANN, para definir o número de camadas ocultas e o número de neurônios por camada, foi realizada uma análise de sensibilidade. Logo, o modelo foi treinado várias vezes variando o número de camadas de 1 a 7, e o número de neurônios de 4 a 512, por camada. A partir da análise das métricas de avaliação, foi implementado o modelo final com 3 camadas ocultas e 256 neurônios.

Em relação à implementação do XGBoost, os autores também realizaram uma análise de sensibilidade a fim de definir seus hiperparâmetros ótimos. Podendo ser citados: “colsample_bytree”, “learning rate”, “max depth”, “min. child weight” e “subsample” com valores de 0,53; 0,13; 9; 3,28 e 0,29; respectivamente. Para uma explicação mais detalhada sobre este método, recomenda-se a referência (2016).

Assim como nos modelos anteriores, também foi realizada uma otimização dos hiperparâmetros para o GPR. Para tanto, o parâmetro “alpha” do modelo foi variado aleatoriamente de 10^{-3} a 10^2 . Este hiperparâmetro é o valor adicionado à diagonal da matriz do kernel durante o processo. Assim, o valor 1,5 foi definido. Para uma explicação mais detalhada sobre este método, os autores recomendam as referências Rasmussen (2003) e Williams & Rasmussen (2006).

Caso outros pesquisadores também queiram testar os modelos, o código em Python está disponibilizado no link <https://github.com/cidengcnpq>. O autor solicita que, caso o código seja utilizado, que se cite o artigo “Predicting the compressive strength of steelmaking slag concrete with machine learning - considerations on developing a mix design tool”.

3.3.2 Normalização

Para a aplicação de técnicas de Aprendizado de Máquina é muito importante que haja no pré-processamento a normalização do conjunto de dados multidimensional. Isso se faz necessário à medida que certos modelos não apresentam boa performance por conta da diferença de escala entre os dados do conjunto, tendendo a dar mais importância a entradas que possuem escalas maiores (FERREIRA, LE e ZINCIR-HEYWOOD, 2019).

A partir da descrição dos dados mostrados na Tabela 7, verifica-se que o aditivo plastificante possui valores entre 0 e 3,6 ($\sigma=0,8\%$), enquanto a escória de aciaria na fração graúda possui valores entre 0 e 2100 ($\sigma=533,2\text{ kg/m}^3$). Portanto, foi utilizada a reescala em cada uma das características do concreto, subtraindo-se a média e definindo-se o desvio-padrão como igual a 1 (FERREIRA, LE e ZINCIR-HEYWOOD, 2019), de acordo com a equação (29):

$$X_i^{new} = \frac{X_i^{old} - \mu}{\sigma} \quad (29)$$

onde:

- X_i^{new} é o novo valor de entrada;
- X_i^{old} é a entrada na escala original;
- μ é a média dos valores da característica;
- σ é o desvio padrão dos valores da característica;

3.3.3 Validação Cruzada

Com o objetivo de minimizar o viés associado à aleatoriedade dos dados de entrada, foram aplicadas técnicas de validação cruzada (KOHAVI, 1995). De acordo com Kohavi (1995), ao invés de apenas dividir os dados somente uma vez em conjuntos de treino e de teste, a validação cruzada faz uma segmentação aleatória dos dados por meio de “k” conjuntos. Dessa forma, a cada divisão, há uma parcela de dados de treino e testes diferentes. Esse método permite que a validação do modelo seja menos tendenciosa do que a simples separação em treino e teste (BLOCKEEL e STRUYF, 2002; KOHAVI, 1995). A Figura 15 ilustra

como funciona esse processo de validação cruzada para $k=10$ conjuntos. As métricas finais de avaliação são a média aritmética das “ k ” simulações.

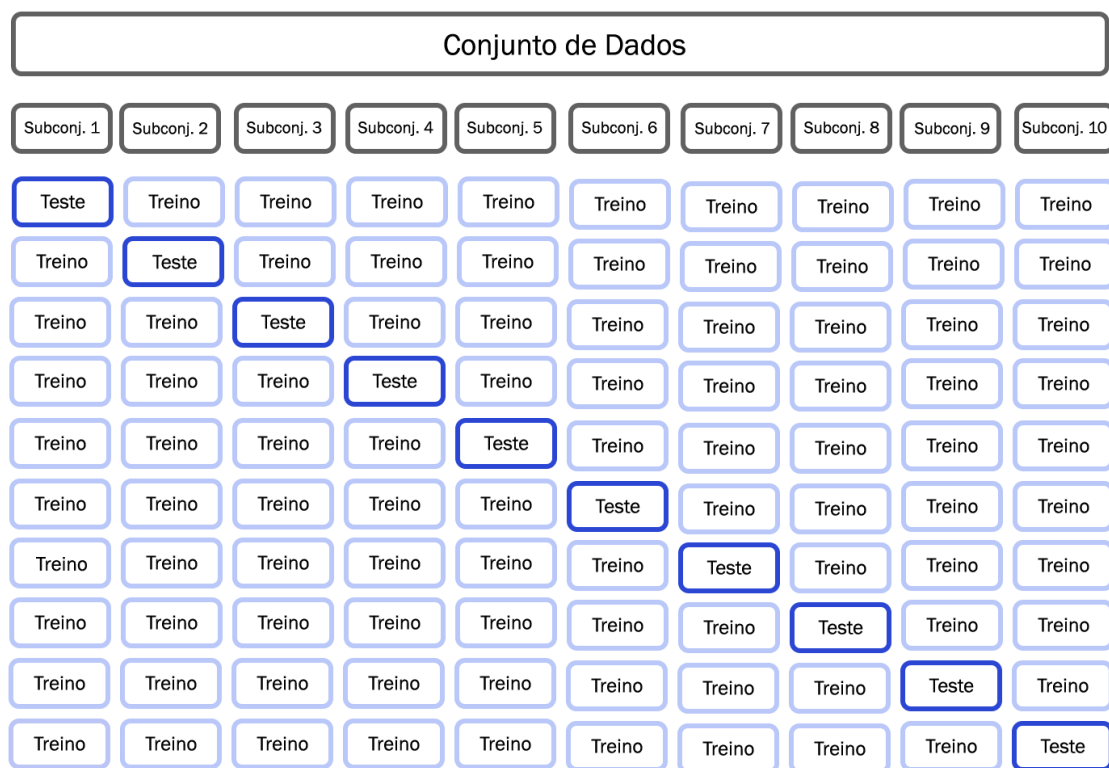


Figura 15 – Funcionamento do Processo de Validação Cruzada para 10 subconjuntos ($k=10$). Fonte: autor

Kohavi (1995) concluiu que mesmo se o poder de processamento do computador permitir a utilização de altos valores para “ k ”, é interessante utilizar a validação cruzada para valores pequenos de “ k ”, como $k \leq 10$. Assim, os modelos propostos neste trabalho foram submetidos a uma validação cruzada com $k = 10$, o que também foi observado em diversos trabalhos semelhantes da literatura (HOANG, PHAM, *et al.*, 2016; BONIFÁCIO, MENDES, *et al.*, 2019; FENG, LIU, *et al.*, 2020). Logo, foi realizada a segmentação aleatória do banco de dados já normalizado em 10 subconjuntos, randomizando a escolha dos dados de treino (90%) e teste (10%).

3.4 Validação Experimental

Após a análise dos modelos com validação cruzada (com valores do próprio banco de dados), foi realizada uma validação com valores experimentais. Para

isso, foram moldados e rompidos 80 corpos de prova de concretos de escória de aciaria no Laboratório de Materiais de Construção Civil da Universidade Federal de Ouro Preto. Foram adotados corpos de prova cilíndricos 10x20 cm, curados em câmara úmida e ensaiados aos 28 dias. A descrição completa do processo de beneficiamento da escória e moldagem dos corpos de prova pode ser encontrada no artigo de Costa et al. (2021).

Esses resultados experimentais integraram um novo banco de dados com 20 instâncias de concretos de escória de aciaria (pois foram rompidos 4 corpos de prova para cada traço), mostrado na Tabela 8. Eles também se encontram na íntegra nos apêndices.

Tabela 8 - Descrição da base de dados de valores experimentais. Fonte: Costa (2021)

Característica	Unidade	Valor mínimo	Valor máximo	Média	Desvio Padrão
Cimento	kg/m ³	310,0	450,0	380,0	70,0
Escória de aciaria na fração miúda	kg/m ³	723,8	1376,4	1047,0	220,8
Escória de aciaria na fração graúda	kg/m ³	815,7	1171,9	991,6	143,3
Água de amassamento	kg/m ³	190,7	236,6	211,7	13,3
Aditivo superplastificante	%	0,1	0,9	0,4	0,2
Adições cimentícias	kg/m ³	0,0	87,1	32,8	25,7
Resistência à compressão	MPa	11,9	41,6	24,8	8,4

3.5 A Qualidade de Ajuste do Modelo

A acurácia da previsão dos modelos, tanto na etapa de validação cruzada quanto na etapa de validação experimental, foi avaliada por meio de três indicadores: MAE, RMSE e R². Essas métricas são extensamente utilizadas para avaliar modelos de regressão neste tipo de problema (CHOU, TSAI, *et al.*, 2014; DEEPA, SATHIYAKUMARI e SUDHA, 2010; BONIFÁCIO, MENDES, *et al.*, 2019).

O erro absoluto médio (MAE, do inglês *mean absolute error*), é uma métrica que mede a magnitude média dos erros (o módulo da diferença entre os valores observados e previstos) (MATSUURA, 2005). Pelo fato de o valor obtido ser absoluto, e não quadrático, grandes erros causados por valores discrepantes (*outliers*) não são tão importantes (DEROUSSEAU, LAFTCHIEV, *et al.*, 2019). O MAE é capaz assumir valores de zero ao infinito positivo, podendo ser calculado

a partir da equação (30), em que y_i são os valores reais do período e p_i são os valores previstos para o período i , tal que $i = 1, 2, \dots, n$. Valores baixos MAE são desejáveis.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - p_i| \quad (30)$$

O RMSE é uma métrica também extensamente utilizada para medir a magnitude dos erros (MATSUURA, 2005). Porém, diferente do MAE, à medida que o erro de cada estimativa aumenta, o RMSE também aumenta consideravelmente, devido à sua característica quadrática (DEROUSSEAU, LAFTCHIEV, *et al.*, 2019). O RMSE é capaz assumir valores de zero ao infinito positivo, podendo ser calculado a partir da equação (31), em que y_i são os valores observados e \hat{y}_i são os valores previstos para o período i , tal que $i = 1, 2, \dots, n$. Valores baixos RMSE são desejáveis

$$RSME = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (31)$$

O R^2 , é uma métrica cujos valores podem variar de menos infinito a 1 (CAMERON e WINDMEIJER, 1997). Dessa forma, caso o modelo se ajuste perfeitamente aos dados, o R^2 assumirá o valor 1, sendo o modelo então capaz de interpretar toda a variabilidade dos dados (DEROUSSEAU, LAFTCHIEV, *et al.*, 2019). Adicionalmente, como o R^2 compara o desempenho do modelo testado com uma linha plana (um modelo de referência em que todas as previsões serão o valor médio das saídas), caso o modelo avaliado apresente um ajuste pior do que essa linha plana de valores médios, o R^2 será negativo. O R^2 pode ser obtido a partir da equação (32), em que y_i são os valores observados, \hat{y}_i são os valores previstos e \bar{y}_i é a média das observações para o período i , tal que $i = 1, 2, \dots, n$.

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (32)$$

4 RESULTADOS

4.1 Criação dos Modelos (com validação cruzada)

4.1.1 Métricas de avaliação

Nessa primeira análise, realizamos, para fins de comparação, a construção do modelo a partir do banco de dados completo (406 instâncias, com todas as idades), e, em seguida, o banco de dados para 28 dias (146 instâncias). A Tabela 9 mostra os resultados com os dados completos para a primeira análise (todas as idades).

Tabela 9 - Métricas de avaliação para cada modelo do banco de dados completo (todas as idades). Fonte: autor

	R ²	ERRO ABSOLUTO MIN [MPA]	ERRO ABSOLUTO MAX [MPA]	MAE	RMSE
GPR	0,89	0,02	34,17	4,71	6,59
ANN	0,91	0,01	37,46	3,93	5,92
XGBoost	0,93	0,01	28,13	3,40	5,08
SVR	0,83	0,01	36,39	5,61	8,11

Observa-se que o modelo baseado no Algoritmo de *Boosting* (*extreme gradient boosting*, em inglês, ou XGBoost) alcançou R² igual a 0,93, o que sugere uma boa capacidade de previsão das resistências. Os modelos baseados nas redes neurais artificiais (*artificial neural networks*, em inglês, ou ANN) e no processo gaussiano de regressão (*gaussian process regression*, em inglês, ou GPR) também obtiveram bons resultados, com R² iguais a 0,91 e 0,89, respectivamente. Em contrapartida, o modelo baseado na SVR obteve um resultado um pouco abaixo dos outros modelos, mesmo que ainda satisfatório, com R² de 0,83. Normalmente um valor de R² acima de 0,90 é considerado uma boa correlação (DAO, ADELI, *et al.*, 2020; HOANG, PHAM, *et al.*, 2016; LORENZI, 2009; CUI, CHEN, *et al.*, 2021).

Neste trabalho, as outras métricas de avaliação (MAE e RMSE) acompanharam a mesma tendência do R², sendo menores para o modelo de XGBoost e maiores para o modelo de SVR. Em uma primeira análise, observa-se que essas métricas demonstraram que os modelos obtiveram bons

desempenhos, principalmente pelo fato de os valores de MAE e RMSE possuírem valores próximos entre si e entre os modelos. No entanto, percebe-se que os erros absolutos máximo chegaram a valores muito altos, cerca de 37 MPa. Esse resultado será discutido a partir da segunda análise, a seguir.

Na segunda análise, realizada a partir do banco de dados para 28 dias (146 instâncias), também foi realizada a validação cruzada com $k = 10$. A Tabela 10 mostra os resultados.

Tabela 10 - Métricas de avaliação para cada modelo do banco de dados para 28 dias. Fonte: autor

	R ²	ERRO ABSOLUTO MIN [MPa]	ERRO ABSOLUTO MAX [MPa]	MAE	RMSE
GPR	0,68	0,01	27,03	4,98	7,09
ANN	0,79	0,05	26,22	4,73	6,52
XGBoost	0,73	0,06	27,95	5,02	6,76
SVR	0,70	0,01	26,59	5,51	7,44

Observa-se na Tabela 10 que a qualidade dos resultados diminui para todos os modelos, e os modelos com os melhores e piores resultados se alteram. O modelo que alcançou o melhor resultado na análise para 28 dias foi o das ANN, com um R² de 0,79, MAE de 4,73 MPa e RMSE de 6,52 MPa. Os modelos XGBoost e SVR obtiveram R² de 0,73 e 0,70, respectivamente. Já o modelo GPR obteve um resultado bem abaixo do ideal, com R² de 0,68, embora os maiores MAE (5,51 MPa) e RMSE (7,44 MPa) tenham sido observados para o modelo SVR.

4.1.2 Discussão

Neste trabalho, as melhores previsões foram obtidas com o XGBoost e as ANN e as piores, com o GPR e SVR. Em um artigo similar, Paixão et al. (2022) também compararam as quatro técnicas, enquanto aplicadas a concretos convencionais. Os autores reportaram que os melhores resultados também foram obtidos para o XGBoost, seguido de perto pelas ANN e GPR, enquanto o SVR obteve os piores. Também é importante relembrar os resultados obtidos por

Osman et al. (2021), citado na seção 2.4.4. Diante do treinamento de três modelos (XGBoost, ANN e SVR), o XGBoost também obteve os melhores resultados.

Na literatura, valores de R^2 da ordem 0,93 são reportados para concretos convencionais (MUSTAPHA e MOHAMED, 2017) e R^2 da ordem de 0,79 a 0,92 para concretos com escória de aciaria (LAM, NGUYEN e LE, 2020). Também para modelos de escória de aciaria, Bian et al. (2021) obtiveram resultados com desvios na ordem de 2,5-5% (0,9 – 2,2 MPa), Gupta et al. (2021) com desvios na ordem de 0,1 MPa. No entanto, é importante mencionar que as técnicas utilizadas não são exatamente as mesmas. Nos artigos de Mustapha e Mohamed (2017), Gupta e Sachdeva (2021), Bian, et al. (2021) e Lam et al. (2020) não foi mencionada a implementação de validação cruzada, dando entendimento de que os dados foram simplesmente separados em treino e teste. Dessa forma, não foram levadas em consideração as possíveis validações tendenciosas e os sobreajustes (*overfitting*) dos modelos. Ademais, as análises de Lam et al. (2020), Gupta e Sachdeva (2021) e Bian et al. (2021) contaram com dados de um único laboratório, sendo moldados especialmente para o estudo. Ressalta-se que esse tipo de abordagem pode limitar a capacidade de generalização do modelo, já que os algoritmos aprenderam de apenas uma fonte homogênea de concreto, o que pode ser pouco representativo (PAIXÃO, PENIDO, *et al.*, 2022).

Vários fatores podem ter contribuído para com essa queda de desempenho observada entre o banco de dados de todas as idades e o de 28 dias. Primeiramente, destaca-se a drástica redução (64%) sofrida pelo banco de dados, diminuindo de 406 para 146 instâncias. Além disso, as predições para 3 e 7 dias geralmente retornam erros menores, já que o módulo e a variabilidade das resistências para essas idades é muito inferior do que para os 28 dias. Isso faz com que as métricas sejam “artificialmente” melhoradas, com menores MAE e RMSE e maiores R^2 , sem necessariamente indicar que os modelos forneceram previsões acuradas para os 28 dias, que são o foco da maioria das obras convencionais. Também podem ser citadas como fontes de erros a alta variabilidade desses dados, que foram provenientes de 17 países, com diferentes materiais de construção e normas; a heterogeneidade da escória, que é um resíduo que tem reconhecida variabilidade; e as diversas conversões utilizadas para a padronização dos corpos de prova.

Observou-se que, apesar de os modelos obterem R², MAE e RMSE razoáveis, os modelos alcançaram erros máximos em torno de 27 MPa. Buscando entender os fatores que levaram a esses altos erros, o autor analisou os 10 traços que levaram aos maiores desvios nos modelos. Entre eles, 5 se repetiam em todos os modelos, como pode ser visto na Tabela 11.

Tabela 11 – 05 traços referentes aos maiores erros que se repetem em todos os modelos

#	Cim	Esc. M	Esc. G	Agr. M	Agr. G	a/c	Aditivo	A Poz	A cim	Filler	Rc Real	GPR	ANN	XGBoost	SVR	Desv. Medio
1	500,0	0,0	1452,0	506,0	0,0	0,3	1,0	0,0	0,0	0,0	81,6	63,0	65,7	53,6	62,8	20,3
2	354,3	939,0	1055,9	0,0	0,0	0,6	0,0	0,0	0,0	0,0	43,0	16,0	25,9	22,5	25,7	20,5
3	424,6	999,8	0,0	0,0	0,0	0,4	0,4	0,0	0,0	0,0	60,7	37,4	35,5	40,2	34,1	23,9
4	416,0	0,0	572,0	624,0	624,0	0,4	0,5	0,0	0,0	0,0	61,7	36,0	37,5	46,6	40,3	21,6
5	526,0	330,0	988,0	330,0	0,0	0,4	0,0	0,0	0,0	0,0	20,6	36,3	36,6	35,7	39,9	-16,5

Em uma análise comparativa com todos os 146 traços, os traços selecionados são provenientes de diferentes autores e países. A maioria se encontra entre os 11% traços com maiores resistências (>57 MPa), mas não se mostram aqueles com maior consumo de cimento ou de agregados de escória. Com exceção do traço #5, que possuía uma resistência real de 20,6 MPa, mesmo possuindo 526 kg/m³ de cimento e 0,4 de fator a/c, os demais traços mostram valores de resistência real compatíveis com o que se espera por seus traços. Essa análise evidencia que a principal causa por trás dos R² inferiores aos trabalhos semelhantes na literatura é o reduzido número de instâncias do banco de dados elaborado pelos autores. Logo, devido à complexa interrelação entre os componentes do concreto de escória de aciaria, aliada ao tamanho limitado do banco de dados e à sua heterogeneidade, não foi possível fornecer informações suficientes para a sua interpretação.

Por outro lado, mesmo com o banco de dados reduzido, os MAE de todos os modelos para 28 dias ficaram entre 4,73-5,51 MPa e o RMSE, 6,52-7,44 MPa. Em uma análise com concretos de alto desempenho de agregados convencionais, Dao *et al.* (2020) obtiveram um MAE de 3,86 MPa e RMSE de 5,46 MPa (usando GPR e ANN em um banco de dados com todas as idades); Mustapha & Mohamed

(2017) obtiveram MAE de 5,89 MPa (usando SVR em um banco de dados com todas as idades, sem validação cruzada); e Hoang *et al.* (2016) alcançaram um RMSE de 4,04 MPa (aplicando GPR em um banco de dados de 246 corpos de prova moldados por eles mesmos). Assim, dada a natureza heterogênea das matrizes cimentícias, da escória de aciaria e da infraestrutura dos canteiros de obras, os resultados obtidos para este trabalho mostram que as técnicas adotadas são promissoras.

4.2 Validação experimental

4.2.1 Métricas de avaliação

A partir de dados experimentais obtidos com o rompimento de corpos de prova em laboratório, foi realizada a validação dos modelos treinados na etapa anterior. Para esta etapa, todas as 146 instâncias foram usadas como treinamento. Os resultados das métricas para os modelos podem ser observados na Tabela 12. Nota-se que em nenhum dos modelos foi possível obter resultados satisfatórios. Inclusive, os modelos de GPR, XGBoost e SVR apresentaram valores de R^2 negativos, indicando que um modelo que utilizasse a média das observações para estimar a resistência do concreto teria um resultado melhor do que o modelo de aprendizagem de máquina proposto. Os desvios entre o valor predito pelos modelos e os experimentais chegam a uma média de mais de 20 MPa para o XGBoost, o que é impraticável em qualquer aplicação real.

Tabela 12 – Validação experimental dos modelos, usando como treinamento o banco de dados para 28 dias. Fonte: autor

	R^2	ERRO ABSOLUTO MIN [MPA]	ERRO ABSOLUTO MAX [MPA]	MAE	RMSE
GPR	-1,37	0,08	25,75	10,93	12,89
ANN	0,32	0,39	16,53	5,51	6,87
XGBoost	-6,79	5,35	41,27	21,12	23,37
SVR	-2,76	1,26	35,61	13,17	16,24

4.2.2 Discussão

Pode-se inferir que são dois os principais fatores causadores de erros para a validação experimental: 1) a qualidade relativamente baixa dos modelos (com R^2 abaixo de 0,8), devido à pequena quantidade de traços disponíveis na literatura para treinamento; e 2) o fato de que os modelos foram treinados com dados de 17 países diferentes, com escórias de diferentes origens e corpos de prova de variados tamanhos e somente validados com corpos de prova do Brasil. Isso indica que a heterogeneidade da escória influencia significativamente as estratégias de aprendizado de máquina utilizadas para prever as propriedades desses concretos.

Validações experimentais como a realizada neste trabalho não foram identificadas em nenhum dos artigos citados. Esse fato leva a indagação se realmente os modelos propostos nestes outros artigos são capazes de fazer boas estimativas com qualquer outro banco de dados ou com concretos reais. Logo, a metodologia proposta por este trabalho evidencia a importância do teste de capacidade de generalização dos modelos de aprendizado de máquina para a segurança das estruturas de concreto.

5 CONCLUSÕES

Este trabalho teve o objetivo de construir modelos baseados em ferramentas de aprendizado de máquina para prever a resistência à compressão de concreto de escória de aciaria com base no seu traço. Para a criação do banco de dados, foi realizada uma revisão sistemática da qual, após análise minuciosa, puderam ser aproveitados 33 trabalhos de 17 países, que levaram a 406 instâncias (observações). Os dados foram normalizados em termos de consumo em kg/m^3 e tamanhos de corpos de prova. O banco de dados serviu para alimentar quatro técnicas de aprendizado de máquina: regressão por vetores suporte (*support vector regression*, em inglês, ou SVR), algoritmo de *boosting* (*extreme gradient boosting*, em inglês, ou XGBoost), processo gaussiano de regressão (*gaussian process regression*, em inglês, ou GPR) e redes neurais artificiais (*artificial neural networks*, em inglês, ou ANN). Em todos os modelos foi realizada a validação cruzada com $k=10$. Por fim, os modelos treinados com os dados da literatura foram validados por meio de resultados experimentais de corpos de prova rompidos em laboratório, no Brasil. Essa etapa de validação experimental não foi observada em outros trabalhos.

Duas análises preliminares foram feitas: uma com o banco de dados completo (todas as idades) e uma com os valores de resistência somente aos 28 dias, o que limitou os dados de treinamento em somente 146 instâncias. O resultado para o banco de dados completo obteve bom desempenho, destacando-se o modelo baseado no XGBoost, com um R^2 de 0,93; MAE de 3,40 MPa e RMSE de 5,08 MPa. Na segunda análise, o modelo que alcançou o melhor resultado foi o das ANN, com um R^2 de 0,79; MAE de 4,73 MPa e RMSE de 6,52 MPa. Na etapa de validação experimental, um diferencial deste trabalho, o desempenho dos modelos caiu drasticamente, levando inclusive a R^2 negativos.

Esses resultados permitiram concluir que o uso de bancos de dados com todas as idades mascara a qualidade real de predição dos modelos. As resistências para menores idades possuem módulos mais baixos e pequena variabilidade, o que geralmente resulta em erros menores. Isso faz com que as métricas MAE, RMSE e R^2 sejam “artificialmente” melhoradas, sem necessariamente indicar que os modelos fornecerão previsões acuradas para os 28 dias, que é o foco da maior parte das aplicações.

As métricas obtidas para a análise de 28 dias indicam que o banco de dados elaborado não foi capaz de fornecer informações suficientes para que os algoritmos conseguissem prever com qualidade a resistência à compressão dos concretos. Isso se deve à complexa interrelação entre os componentes de concretos em geral e à variabilidade das propriedades da escória de aciaria. A insuficiente quantidade de dados que estão disponíveis na literatura atualmente inviabiliza, neste momento, a construção de um banco de dados maior e mais representativo, que nos permitiria a criação de modelos com maior qualidade.

A validação experimental permitiu concluir que os modelos ainda não conseguiram alcançar uma adequada capacidade de generalização, isto é, de serem aplicados para bancos de dados diferentes dos utilizados no treinamento. O tamanho limitado do banco de dados de treinamento e a regionalidade dos concretos de escória rompidos afetaram significativamente os resultados. Para este último fator, o autor recomenda que sejam feitos mais estudos quantificando essa influência regional na capacidade de generalização de modelos de aprendizado de máquina.

Em conclusão, apesar de as métricas de avaliação ainda não serem ideais, os resultados obtidos indicam que as técnicas de aprendizado de máquina são promissoras, embora ainda impraticáveis de serem implementadas em escala global com os limitados dados que estão disponíveis atualmente. Assim, com mais dados, acredita-se que no futuro será possível construir um modelo suficientemente eficiente e robusto para a definição de traços de concretos de escória de aciaria no Brasil e no mundo.

5.1 Sugestões para trabalhos futuros

A partir dos resultados e das conclusões obtidas por meio deste trabalho, sugere-se a avaliação futura dos seguintes itens:

- Definição de valores de correlação de corpos de prova de concreto de escoria de aciaria de diferentes tamanhos.
- Aumento do banco de dados para incluir mais instâncias de diversos países, incluindo o país como variável.

- Treinamento de modelos com a finalidade de se determinar, além da resistência à compressão, outras propriedades de concretos de escória de aciaria e de outros concretos baseados em resíduos.
- Avaliação da influência da regionalidade na qualidade dos modelos de aprendizado de máquina para previsão da resistência à compressão de concretos em geral.

6 REFERÊNCIAS

ABNT. NBR 10004:2004 - Resíduos Sólidos - Classificação. **Associação Brasileira de Normas Técnicas**, p. 71, Maio 2004.

ABNT. NBR 7211 - Agregados para Concreto - Especificação. **Associação Brasileira de Normas Técnicas**, Rio de Janeiro, p. 12, 2009.

ABNT. NBR 6118 - Projeto de Estruturas de Concreto - Procedimento. **Associação Brasileira de Normas Técnicas**, Rio de Janeiro, 2014.

ABNT. NBR 12655 - Concreto de cimento Portland — Preparo, controle, recebimento e aceitação — Procedimento. **Associação Brasileira de Normas Técnicas**, Rio de Janeiro - RJ, 2015.

ABNT. NBR 5739:2018 - Concreto - Ensaio de Compressão de Corpos-de-Prova Cilíndricos. **Associação Brasileira de Normas Técnicas**, Rio de Janeiro, 2018.

ABNT. NBR 16889 - Concreto - Determinação da Consistência pelo Abatimento do Tronco de Cone. **Associação Brasileira de Normas Técnicas**, Rio de Janeiro, p. 5, 2020.

ACI. ACI 318 - Building Code Requirements for Structural Concrete. **American Concrete Institute**, 2008.

ATICI, C. Prediction of the Strength of Mineral-Addition. **Magazine of Concrete Research**, v. 62, n. 8, p. 585-592, August 2010.

AWAD, M.; KHANNA, R. Livro Efficient Learning Machines: Theories, Concepts and Applications for Engineers and System Designers, n. 1ª, 2015.

BASHEER, I. A.; HAJMEER, M. Artificial Neural Network: fundamentals, computing, design and application. **Journal of Microbiological Methods**, Manhattan, 2000.

BBC. Aquecimento global: a gigantesca fonte de CO2 que está por toda parte, mas você talvez não saiba. **BBC News | Brasil**, 2018. Disponível em: <https://www.bbc.com/portuguese/geral-46591753?ocid=socialflow_facebook&fbclid=IwAR2IjNB6LgBs90rApfIW-YUujEMMQxPFxb7fSs0rLOAf4IsXVUYW9cfjDO4>. Acesso em: 13 Dezembro 2021.

BEZERRA, A. C. D. S. Influência Das Variáveis De Ensaio Nos Resultados De Resistência à Compressão de Concretos: uma Análise Experimental e Computacional. **Dissertação - Escola de Engenharia da UFMG**, Belo Horizonte, 2007.

BHANJA, S.; SENGUPTA, B. Investigations on the compressive strength of silica fume. **Cement and Concrete Research**, v. 32, p. 1391-1394, 2002.

BIAN, Z. et al. Numerical Simulation of Basic Properties of Full-Steel Slag. **Hindawi - Advances in Civil Engineering**, China, Junho 2021.

BISHOP, C. M. Pattern Recognition and Machine Learning. **Springer. Cambridge**, New York. USA, n. 1ª, 2006.

BLOCKEEL, H.; STRUYF, J. Efficient Algorithms for Decision Tree Cross-Validation. **Journal of Machine Learning Research**, p. 621-650, 2002.

BOGGIO, A. J. Estudo Comparativo de Métodos de Dosagem de Concreto de Cimento Portland. **Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2000.

BONIFÁCIO, A. L. et al. Application of Support Vector Machine and Finite Element Method to predict the mechanical properties of concrete. **Latin American Journal of Solids and Structures**, Rio de Janeiro, v. 16, Agosto 2019.

BONIFÁCIO, A. L. et al. Application of Support Vector Machine and Finite Element Method to predict the mechanical properties of concrete. **Latin American Journal of Solids and Structures**, v. 16, 2019.

BORGES, L. A. Desempenho de Concretos Produzidos com Nanotubos de Carbono Sintetizados Diretamente sobre o Clínquer. **Dissertação - Escola de Engenharia da UFMG**, Belo Horizonte, 2019.

BURGES, C. J. C. A Tutorial on Support Vector Machines for Pattern Recognition. **Data Mining and Knowledge Discovery**, v. 2, p. 121-167, 1998.

CAIXA ECONÔMICA FEDERAL. Referência de Insumo e Composições - SINAPI. **Caixa Econômica Federal**, Novembro 2021. Disponível em: <<https://www.caixa.gov.br/poder-publico/modernizacao-gestao/sinapi/Paginas/default.aspx>>. Acesso em: 15 Janeiro 2021.

CAMERON, A. C.; WINDMEIJER, F. A. An R-squared measure of goodness of fit for some common nonlinear regression models. **Journal of econometrics**, p. 329-342, 1997.

CATUSO, A. et al. Influência da Exsudação na Profundidade de Carbonatação em Concretos. **Anais do 5º Congresso Brasileiro do Concreto**, Outubro 2015.

CAVALCANTI, R. D. S. Ensaio de Ondas Ultrassônicas e Redes Neurais Artificiais na Avaliação da Resistência à Compressão do Concreto. **Universidade Católica de Pernambuco**, Recife, 2010.

CHAURAND, P. et al. Environmental impacts of steel slag reused in road construction: A crystallographic and molecular (XANES) approach. **Journal of Hazardous Materials**, Amsterdã, Países Baixos, v. 139, p. 537-542, January 2007.

CHEN, M. et al. Machine Learning for Wireless Networks with Artificial Intelligence: A Tutorial on Neural Networks. **Beijing University of Posts and Telecommunications**, Beijing, China, 2017.

CHEN, R. et al. Prediction of Shield Tunneling-Induced Ground Settlement. **Frontiers of Structural and Civil Engineering**, September 2019.

CHEN, T.; GUESTRIN, C. XGBoost: A Scalable Tree Boosting System. **Association for Computing Machinery**, San Francisco, CA, USA, p. 785-794, August 13-17 2016.

CHOU, J.-S. et al. Machine learning in concrete strength simulations: Multi-nation data. **Construction and Building Materials**, v. 73, p. 771-780, December 2014.

CHOU, J.-S.; NGO, N.-T.; PHAM, A.-D. Shear Strength Prediction in Reinforced Concrete Deep Beams Using Nature-Inspired Metaheuristic Support Vector Regression. **Journal of Computing in Civil Engineering**, v. 30, January 2016.

COSTA, L. C. B. et al. Mechanical and durability performance of concretes produced with steel slag aggregate and mineral admixture, Laboratory of Materials

for Civil Construction, Federal University of Ouro Preto. Ouro Preto, Minas Gerais, Brazil, p. em revisão, 2021.

CUI, L. et al. Application of Extreme Gradient Boosting Based on Grey Relation Analysis for Prediction of Compressive Strength of Concrete. **Advances in Civil Engineering**, 2021.

DA SILVA, M. J. et al. Feasibility study of steel slag aggregates in precast concrete pavers. **Materials J.**, v. 113, n. 4, p. 439-446, 2016.

DAO, D. V. et al. A sensitivity and robustness analysis of GPR and ANN for high-performance concrete compressive strength prediction using a Monte Carlo simulation. **Sustainability**, p. 830, 2020.

DE FREITAS, S. M. A. C. Escória de Aciaria: Caminhos para uma Gestão. **Universidade Federal de Ouro Preto**, Ouro Preto, Abril 2018.

DE FREITAS, S. M. A. C. et al. Steel slag and Iron Ore Tailings to Produce Solid Brick. **Clean Technologies and Environmental Policy**, v. 20, n. 5, p. 1087-1095, 2018.

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

DEROUSSEAU, M. A. et al. comparison of machine learning methods for predicting the compressive strength of field-placed concrete. **Construction and Building Materials**, v. 228, 2019.

DIETTERICH, T. G. Ensemble Methods in Machine Learning. **Lecture Notes in Computer Science**, Berlin Heidelberg, v. 1857, p. 1-15, December 2000.

DINIZ, D. H. Influence of steelwork slag filler as stabilizer of soils. **Federal Center of Technological Education of Minas**, Belo Horizonte, Brazil, 2009.

DINIZ, D. H. et al. Blast Oxygen Furnace Slag as Chemical Soil Stabilizer for Use in Roads. **Journal of Materials in Civil Engineering**, v. 29, n. 9, September 2017.

DONG, W. et al. XGBoost algorithm-based prediction of concrete electrical resistivity for structural health monitoring. **Automation in Construction**, Australia, v. 114, June 2020.

EUROCODE 2. Design of Concrete Structures - part 1-1: General rules and rules for buildings. **The European Union**, Brussels, December 2004.

FARIA, R. A. F. Contribuição ao Estudo das Propriedades Mecânicas e da Durabilidade de Concretos com Escória de Aciaria Elétrica (EAF) como Agregado Graúdo. **Universidade Federal de Goiás**, Goiânia, 2007.

FEITOSA, R. D. F. et al. Statistical Pattern Recognition for Thresholding between Human Skin and Background in Color Images. **JOURNAL OF COMPUTER SCIENCES**, Goiás, Brazil, v. 13, p. 22-33, 2017.

FENG, D. C. et al. Machine Learning-based Compressive Strength Prediction for Concrete: An adaptive boosting approach. **Construction and Building Materials**, p. 230, 2020.

FERREIRA, P.; LE, D. C.; ZINCIR-HEYWOOD, N. Exploring feature normalization and temporal information for machine learning based insider threat detection. **2019 15th International Conference on Network and Service Management**, p. 1-7, October 2019.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. D. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, 2019.

FLACH, P. Machine Learning: The Art and Science of Algorithms that Make Sense of Data. **Cambridge University Press**, New York, 2012.

G1. Comissão visita montanha de escória formada por resíduos da CSN em Volta Redonda. **G1 - Sul do Rio e Costa Verde**, 2018. Disponível em: <<https://g1.globo.com/rj/sul-do-rio-costa-verde/noticia/comissao-visita-montanha-de-escoria-formada-por-residuos-da-csn-em-volta-redonda.ghtml>>. Acesso em: 30 de novembro de 2021 Novembro 2021.

GAMA, R. S.; NETO, E. F.; RABELO, A. A. Substituição Parcial de Agregado por Escória de Forno Panela. **5º Congresso Iberoamericano de Cerâmica**, Maio 2013.

GARCIA, S. C. O Uso de Árvores de Decisão na Descoberta de Conhecimento na Área da Saúde. **Universidade Federal do Rio Grande do Sul. Instituto de Informática**, Porto Alegre, 2003.

GEYER, R. M. T. Estudo Sobre a Potencialidade de Uso das Escórias de Aciaria como Adição ao Concreto. **Universidade Federal do Rio Grande do Sul**, Porto Alegre, p. 1, 2001.

GONÇALVES, A. R. Máquinas de Vetores Suporte. **Universidade Estadual de Campinas**, Campinas, 2015.

GONÇALVES, D. R. et al. Evaluation of the economic feasibility of a processing plant for steelmaking slag. **Waste Management & Research**, v. 34, n. 2, p. 107-112, 2016.

GUMIERI, A. G.; PAGNUSSAT, D. T.; DAL MOLIN, D. C. C. The use of steel slag as mineral admixture to the concrete. **Sustainable construction into the next millenium environmentally, friendly and innovative cement bases materials**, João Pessoa, 2000.

GUPTA, T.; SACHDEVA, S. N. A Novel Approach for Predicting the Compressive and Flexural Strength of Steel Slag Mixed Concrete Using Feed-Forward Neural Network. **Advances in Civil Engineering**, Índia, 2021.

GURNEY, K. An Intruduction to Neural Networks. **University College London**, London & New York, n. 1^a, p. 22-28, 1997.

HOANG, N. D. et al. Estimating compressive strength of high performance concrete with Gaussian process regression model. **Advances in Civil Engineering**, v. 2016, 2016.

HOANG, N.-D. et al. Estimating compressive strength of high performance concrete with Gaussian process regression model. **Advances in Civil Engineering**, Vietnam, v. 2016, September 2016.

INSTITUTO AÇO BRASIL. Estatísticas da Siderurgia - Steel Statistics. **AÇO BRASIL**, 2021. Disponível em: <https://acobrasil.org.br/site/wp-content/uploads/2021/11/EM_Outubro_2021_946855933.pdf>. Acesso em: 09 dezembro 2021.

JOSHI, M. V.; AGARWAL, R. C.; KUMAR, V. Predicting Rare Classes: Can Boosting Make Any Weak Learner Strong? **Association for Computing Machinery. Proceedings of the eighth ACM SIGKDD international conference**

on **Knowledge discovery and data mining**, New York, NY, USA, p. 297-306, July 2002.

KAGGLE. BCI Challenge @ NER 2015. **Kaggle**, 2015. Disponível em: <<https://www.kaggle.com/c/inria-bci-challenge/leaderboard>>. Acesso em: 09 February 2022.

KOHAVI, R. A Study of Cross-Validation and Bootstrap. **International Joint Conference on Artificial Intelligence**, p. 1137-1143, 1995.

LAM, N. T. M.; NGUYEN, D. L.; LE, D. H. Predicting compressive strength of roller-compacted concrete pavement containing steel slag aggregate and fly ash. **International Journal of Pavement Engineering**, p. 1-14, 2020.

LAREX-USP. Laboratory of recycling, waste treatment and extracion. **Larex - Universidade de São Paulo. São Paulo**, 2020. Disponível em: <<http://larex.poli.usp.br/en/reciclagem-da-escoria-de-aciaria/>>. Acesso em: 01 Dezembro 2020.

LEÓN, A. J. E. et al. Caracterização dos Vazios de Concretos Asfálticos a partir da Microtomografia Computadorizada e da Segmentação por Machine Learning. **34° Congresso de Pesquisa e Ensino em Transporte da ANPET**, Novembro 2020.

LI, S.-C. et al. Gaussian process model of water inflow prediction in tunnel construction. **Tunnelling and Underground Space Technology**, China, v. 69, p. 155-161, June 2017.

LIMA, A. R. G. Máquinas de Vetores Suporte na Classificação de Impressões Digitais. **Universidade Federal do Ceará, Departamento de Computação**, Fortaleza, Ceará, 2002.

LORENZI, A. Aplicação de Redes Neurais Artificiais para Estimativa da Resistência à Compressão do concreto a partir da velocidade de Propagação de Pulso Ultrassônico. **Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2009.

LORENZI, A.; FILHO, L. C. P. S.; CAMPAGNOLO, J. L. Desenvolvimento de Redes Neurais Artificiais para Interpretação de Ensaios de Velocidade de

Propagação de Pulso Ultrassônico no Concreto. **Revista IBRACON de Estruturas e Materiais**, v. 4, p. 829-844, 2011. ISSN 5.

MARMITTI, B. A. et al. Estudo Comparativo de Métodos para Dosagem Concreto. **Congresso Técnico Científico da Engenharia e da Agronomia**, Foz do Iguaçu, Agosto 2016.

MARTINS, A. C. P. et al. Steel slags in cement-based composites: An ultimate review on characterization, applications and performance. **Construction and Building Materials**, v. 291, 2021.

MARTINS, C. A. C. Estimativa da Profundidade de Carbonatação do Concreto com o Uso de Redes Neurais. **Universidade Católica de Pernambuco**, Recife, 2011.

MATSUURA, C. J. W. A. K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate research**, p. 79-82, 2005.

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto Microestrutura, Propriedades e Materiais**. 2ª. ed. [S.l.]: IBRACON, 2014.

MIRAQUI, M.; ZENTAR, R.; ABRIAK, N. Road material basis in dredged sediment and basic oxygen furnace steel slag. **Construct and Building Materials**, v. 30, p. 309-319, 2012.

MOMENI, E. et al. Gaussian Process Regression Technique to Estimate the Pile Bearing Capacity. **Arabian Journal for Science and Engineering**, v. 45, n. 10, p. 8255-8267, May 2020.

MONARD, M. C.; BARANAUSKAS, J. A. **Conceitos Sobre Aprendizado de Máquina. Sistemas Inteligentes Fundamentos e Aplicações**. 1. ed. Barueri-SP: Manole Ltda, v. ISBN 85-04-168, 2003.

MURPHY, K. P. Livro: Machine Learning: A Probabilistic Perspective. **Massachusetts Institute of Technology**, London, England, p. 33-34, 2012.

MUSTAPHA, R.; MOHAMED, E. A. High-performance concrete compressive strength prediction based weighted support vector machines. **International Journal of Engineering Research and Applications**, v. 7, n. 1, p. 68-75, 2017.

NEVILLE, A. M. **Propriedades do Concreto**. 5ª. ed. Porto Alegre: Bookman, 2016.

NOBLE, W. S. What is a support vector machine. **Nature biotechnology**, p. 1565-1567, 2006.

OSMAN, A. I. A. et al. Extreme gradient boosting (Xgboost) model to predict the groundwater levels in Selangor Malaysia. **Ain Shams Engineering Journal**, Selangor, Malaysia, v. 12, p. 1545-1556, January 2021.

PAIXÃO, R. C. F. D. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. **IBRACON Structures and Materials Journal**, p. Em Revisão, 2022.

PARSA, A. B. et al. Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis. **Accident Analysis & Prevention**, v. 136, March 2020. ISSN 105405.

PEREIRA, M. D. S. Controle da Resistência do Concreto. **Universidade de Brasília. Faculdade de Tecnologia.**, Brasília/DF, Novembro 2008.

PINTO, D. F. F. Caracterização Experimental do Comportamento da Liga AlSi9Cu3 em Condições de Maquinagem. **Faculdade de Engenharia - Universidade do Porto**, Porto, Portugal, junho 2017.

POLISSENI, A. E. Tese: Estudo da Viabilidade Técnica da Utilização de Escória de Aciaria Elétrica Micronizada como Material Cimentício. **Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2005.

REVISTA CONSTRUA. As 5 patologias mais comuns da construção civil. **Revista Construa**, 2020. Disponível em: <<https://revistaconstrua.com.br/noticias/engenharia/as-5-patologias-mais-comuns-da-construcao-civil/>>. Acesso em: 07 Fevereiro 2022.

RODRIGUES, G. L. C. Caracterização e Avaliação da Expansibilidade de Escórias de Aciaria LD Não Tratadas e Tratadas. **Universidade Federal do Espírito Santo**, Vitória, 2007.

RODRIGUES, P. P. F. Parâmetros de Dosagem do Concreto. **ET - 67**, São Paulo: ABCP, 1990.

ROKACH, L.; MAIMON, O. **Data Mining With Decision Trees: Theory and Applications**. 2nd. ed. London: World Scientific, 2015.

SCHAPIRE, R. E. A Brief Introduction to Boosting. **Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence**, USA, v. 2, p. 1401-1406, July 1999.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and computing**, p. 199-222, 2004.

SOUZA, E. B. D. O. E. Escórias de Aciaria e Resíduos de Concretos Refratários em Componentes de Pavimentação. **Universidade Federal de Minas Gerais**, Belo Horizonte, 2007.

SOUZA, V. C. M. D.; RIPPER, T. **Patologia, Recuperação e Reforço de Estruturas de Concreto**. Padrão. ed. [S.l.]: PINI, 1998.

TUBINO, R. M. C. Aproveitamento de Escórias Siderúrgicas na Construção Civil. **Construção Em Goiás**, Goiânia, p. 4-9, 2001. ISSN 414.

TUTIKIAN, B.; HELENE, P. Concreto: Ciência e Tecnologia. **Capítulo 12: Dosagem do Concretos de Cimento Portland**, v. 1, n. 1^a, 2011.

VERDÉRIO, A. Sobre o Uso de Regressão por Vetores Suporte para a Construção de Modelos em um Método de Região de Confiança sem Derivadas. **Universidade Federal do Paraná**, Curitiba, 2015.

WAN, Z. Y.; SAPSIS, T. P. Reduced-space Gaussian Process Regression for data-driven probabilistic forecast of chaotic dynamical systems. **Physica D: Nonlinear Phenomena**, Massachusetts, United States, v. 345, p. 40-55, January 2017.

WILLIAMS, C. K.; RASMUSSEN, C. E. **Gaussian processes for machine learning**. 3. ed. Massachusetts: MIT press, v. 2, 2006.

WORLD STEEL ASSOCIATION. Global Crude Steel Output Increases by 3.4% in 2019. **World Steel Association**, 2019. Disponível em: <<https://www.worldsteel.org/media-centre/press-releases/2020/Global-crude-steel-output-increases-by-3.4--in-2019.html>>. Acesso em: 04 Fevereiro 2021.

YASA, R.; ETEMAD-SHAHIDI, A. Classification and Regression Trees Approach for Predicting Current-Induced Scour Depth Under Pipelines. **Journal**

of Offshore Mechanics and Arctic Engineering, Australia, v. 136, February 2014.

YEH, I. C. Modeling of strength of high-performance concrete using artificial neural networks. **Cement and Concrete research**, p. 1797-1808, 1998.

YI, S.-T.; YANG, E.-I.; CHOI, J.-C. Effect of specimen sizes, specimen shapes, and placement directions on compressive strength of concrete. **Nuclear Engineering and Design**, South Korea, v. 236, p. 115-127, January 2006.

YING, Y. et al. Applications of Machine Learning In Pipeline Monitoring. **Carnegie Mellon University**, Pittsburg, California, 2011.

7 APÊNDICES

7.1 Artigos

Publicado: Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization

- Authors: Rafael Christian Fonseca da Paixão; Rúben El-Katib Penido, Alexandre Abrahão Cury; Júlia Castro Mendes
- DOI: 10.1590/S1983-41952022000500003
- Journal: IBRACON *Structures and Materials Journal*
- Impact Factor: 0,5

Em revisão: Predicting the compressive strength of steelmaking slag concrete with machine learning - considerations on developing a mix design tool

- Authors: Rúben El-Katib Penido, Rafael Christian Fonseca da Paixão; Alexandre Abrahão Cury; Júlia Castro Mendes
- DOI:
- Journal: *Construction and Building Materials*
- Impact Factor: 6,14

7.2 Revisão da literatura realizada pelo autor

A revisão da literatura realizada pelo autor (118 arquivos) se encontra nas Tabela 13, 14 e 15 e também pode ser encontrada na íntegra no Github do CIDENG: <https://github.com/cidengcnpg>.

7.2.1 Fonte: Google Scholar

Tabela 13 – Fontes adotadas para elaboração das tabelas – resultados do Google Scholar. Fonte: autor

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
1	Carbonatação em concreto de escória de aciaria	ANDRADE	Dissertação	2018	Brasil	Incluso
2	Desempenho de concretos de escória de aciaria frente a ataque de cloretos	COSTA	Dissertação	2019	Brasil	Incluso
3	Coeficiente de conformação superficial de armaduras em concreto sustentável: escória de aciaria	MARINO	TCC	2016	Brasil	TCC (fora do escopo da proposta)
4	Contribuição ao Estudo das Propriedades Mecânicas e da Durabilidade de Concretos com Escória de Aciaria Elétrica (EAF) como Agregado Graúdo	FARIA	Dissertação	2007	Brasil	Incluso
5	Potencialidade do uso da escória de aciaria na produção de blocos de concreto para pavimentação	MALTEZ ET AL.	Artigo	2017	Brasil	Fabricação de blocos de concreto para pavimentação (fora do escopo da proposta)
6	Escória de aciaria: caminhos para uma gestão sustentável	FREITAS	Tese	2018	Brasil	Fabricação de tijolos maciços (fora do escopo da proposta)
7	Utilização de escória de aciaria na fabricação de blocos de concreto	BENITTEZ	Dissertação	2020	Brasil	Fabricação de blocos de concreto (fora do escopo da proposta)
8	Estudo de viabilidade da utilização da escória de aciaria na redução da expansão causada no concreto pela reação álcali-agregado	ZOLETT E SOUZA	TCC	2012	Brasil	TCC (fora do escopo da proposta).

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
9	Emprego de escórias de aciaria elétrica como adição a concretos	MASUERO ET AL.	Artigo	2000	Brasil	Escória de aciaria Como adição mineral (fora do escopo da Proposta).
10	Utilização das Escórias de Aciaria Elétrica e Aciaria como Adição ao Concreto - Resistência Mecânica	SALANI ET AL.	Artigo	1999	Brasil	Escória de aciaria como adição mineral (fora do escopo da proposta).
11	Avaliação da durabilidade do concreto da construção civil com a utilização de agregados de escória de aciaria LD	ZAGO, S. C.	Tese	2019	Brasil	Incluso
12	Determinação experimental do módulo de elasticidade do concreto convencional e com agregados de escória de aciaria	STIEF ET AL.	Artigo	2009	Brasil	Incluso
13	Uso do pó e agregados de Escória de Aciaria em misturas estabilizadas e em concretos para sub-base e pavimento	FIOROTTI	Artigo	2014	Brasil	Concretos para infraestrutura viária (fora do escopo da proposta).
14	Caracterização Físico-Química de Agregados de Escória de Aciaria LD Pós-processada para Concretos Sustentáveis	DE SOUZA ET AL.	Artigo	2016	Brasil	Incluso
15	Contribuição ao estudo do fenômeno da Instabilidade Volumétrica das Escórias de Aciaria elétrica	MANCIO	Dissertação	2001	Brasil	Apenas caracterização da escória, não possui os dados necessários.
16	Substituição parcial de agregado por escória de forno panela em concretos convencionais	GAMA ET AL.	Artigo	2013	Brasil	Não fornece os valores de massas específicas de nenhum dos agregados, a fim de possibilitar o cálculo do consumo de cimento [kg/m ³]
17	Utilização de escória granulada de fundição (EGF) em blocos de concreto para pavimentação	PAGNUSSAT	Dissertação	2004	Brasil	Blocos de concreto para pavimentação (fora do escopo)

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
18	Utilização de resíduos da indústria siderúrgica na fabricação de blocos de concreto para pavimentação	SILVA ET AL.	Artigo	2011	Brasil	Escória granulada de fundição (fora do escopo da proposta) blocos de concreto para pavimentação (fora do escopo da proposta).
19	Caracterização do fator expansão de uma escória de aciaria em diferentes processos de cura para uso em pavimentação	BALTAZAR	Tese	2001	Brasil	Concreto para uso em pavimentação (fora do escopo da proposta).
20	Avaliação Do Potencial Do Reaproveitamento Da Escória De Aciaria LD Como Agregado Siderúrgico	OLIVEIRA ET AL.	Artigo	2018	Brasil	Avalia a escória, mas não trata sobre resistência à compressão
21	Modelagem do comportamento mecânico de blocos e prismas produzidos com escória de aciaria elétrica para alvenaria estrutural	JANUZZI	Dissertação	2014	Brasil	Blocos para alvenaria estrutural (fora do escopo da proposta)
22	Estudo de viabilidade da utilização da escória de aciaria na redução da expansão causada no concreto pela reação álcali- agregado	ZOLETT E SOUZA	Artigo	2016	Brasil	TCC (fora do escopo da proposta).
23	Influence of steel slag on mechanical properties and durability of concrete	WANG ET AL.	Artigo	2013	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
24	Use of low CaO unprocessed steel slag in concrete as fine aggregate	QASRAWI ET AL.	Artigo	2009	Jordânia	Incluso
25	Recycling of industrial waste and performance of steel slag green concrete	LI ET AL.	Artigo	2009	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
26	Properties of concrete manufactured using steel slag	DEVI ET AL.	Artigo	2014	Índia	Incluso
27	Performance of concrete mixtures made with electric arc furnace (EAF) steel slag aggregate produced in the Arabian Gulf region	ABU-EISHAH ET AL.	Artigo	2012	Emirados Árabes Unidos	Incluso

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
28	Comparison of the properties between high-volume fly ash concrete and high-volume steel slag concrete under temperature matching curing condition	MENGXIAO ET AL.	Artigo	2015	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
29	Utilisation of steel slag as an aggregate in concrete	NETINGER ET AL.	Artigo	2011	Croácia	Incluso
30	Performance of concrete made with steel slag and waste glass	YU ET AL.	Artigo	2016	Austrália	Incluso
31	Utilization of fine recycled aggregates in concrete with fly ash and steel slag	ANASTASIOU ET AL.	Artigo	2014	Grécia	Incluso
32	Performance of steel slag and steel sludge in concrete	ROSLAN ET AL.	Artigo	2016	Malásia	Escória de aciaria como adição mineral (fora do escopo da proposta).
33	Possibility of concrete prepared with steel slag as fine and coarse aggregates	CHUNLIN ET AL.	Artigo	2011	China	Não é fornecida a relação dos agregados para com o cimento, inviabilizando a extração dos dados Necessários.
34	The potential use of steel slag in refractory concrete	DUCMAN ET AL.	Artigo	2011	Eslovênia	Concreto refratário (fora do escopo da proposta).
35	Accelerated carbonation and performance of concrete made with steel slag as binding materials and aggregates	MO ET AL.	Artigo	2017	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
36	Utilization of unprocessed steel slag as fine aggregate in normal- and high-strength concrete	GUO ET AL.	Artigo	2019	China	Incluso
37	Properties of concrete containing electric arc furnace steel slag and steel sludge	ROSLAN ET AL.	Artigo	2020	Malásia	Escória de aciaria como adição mineral (fora do escopo da proposta).
38	On the use of blast furnace slag and steel slag in the preparation of green artificial reef concrete	HUANG ET AL.	Artigo	2016	China	Incluso
39	Utilization of carbonated and granulated steel slag aggregate in concrete	PANG ET AL.	Artigo	2015	China	Incluso

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
40	Mechanical and durability characteristics of High Performance Concrete containing steel slag and crystalized slag as aggregates	BISKRI ET AL.	Artigo	2017	Argélia	Incluso
41	The use of steel slag aggregate to enhance the mechanical properties of recycled aggregate concrete and retain the environment	QASRAWI	Artigo	2014	Jordânia	Todos os traços possuem agregados de concreto reciclado (fora do escopo da proposta).
42	Broader use of steel slag aggregates in concrete	PATEL	Dissertação	2008	Índia	O artigo não diferencia a quantidade de agregados graúdos e Miúdos.
43	Instant-chilled steel slag aggregate in concrete— Fracture related properties	MONTGOMERY AND WANG	Artigo	1992	Austrália	Quantidade de agregados graúdos e miúdos, o que inviabiliza a correta extração e análise Dos dados.
44	Durability studies on eco-friendly concrete mixes incorporating steel slag as coarse aggregates	PALANKAR ET AL.	Artigo	2016	Índia	Concreto de cimento álcali ativado (fora do escopo da proposta).
45	Investigation on compressive characteristics of steel-slag concrete	NGUYEN ET AL.	Artigo	2020	Vietnã	Incluso
46	Applications of steel slag powder and steel slag aggregate in ultra- high performance concrete	LIU AND GUO	Artigo	2018	China	Concretos acima de 150 mpa (fora do escopo da proposta). Os traços possuem fibras metálicas (fora do escopo).
47	Influence of steel slag-silica fume composite mineral admixture on the properties of concrete	LIU ET AL.	Artigo	2017	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
48	Concrete with EAF steel slag as aggregate: A comprehensive technical and environmental characterisation	RONDI ET AL.	Artigo	2016	Itália	100% escória de aciaria, mas não diferencia escória graúda e miúda, o que inviabiliza a extração e análise Dos dados.

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
49	Effect of electric arc furnace steel slag on the mechanical and fracture properties of roller- compacted concrete	ROOHOLAMI NI ET AL.	Artigo	2019	Irã	Concreto compactado a rolo (rcc) - fora do escopo da proposta
50	Utilization of steel slag in ultra-high performance concrete with enhanced eco-friendliness	ZHANG ET AL.	Artigo	2019	China	Escória de aciaria como adição mineral (fora do escopo da proposta). Adição de fibra metálicas (fora do escopo)
51	Impact of use of steel slag as coarse aggregate and wastewater on fresh and hardened properties of concrete	SAXENA AND TEMBHURKA R	Artigo	2018	Índia	Incluso
52	Laboratory investigation and modeling of concrete pavements containing AOD steel slag	GUPTA AND SACHDEVA	Artigo	2019	Índia	Concreto para pavimentação (fora do escopo). Escória de aciaria apenas como substituição de cimento (fora do escopo).
53	Usage of steel slag in concrete as fine and/or coarse aggregate	SEZER AND GULDEREN	Artigo	2015	Turquia	Incluso
54	Durability of steel fiber reinforced concrete with coarse steel slag aggregates including performance at elevated temperatures	PAPACHRIST OFOROU ET AL.	Artigo	2020	Grécia	Incluso
55	Properties of pervious concrete with steel slag as aggregates and different mineral admixtures as binders	ZHANG ET AL.	Artigo	2020	China	Concreto permeável (fora do escopo da proposta).
56	Autogenous and engineered healing mechanisms of carbonated steel slag aggregate in concrete	PANG ET AL.	Artigo	2016	China	Não analisa a resistência à compressão.
57	A new formulation for strength characteristics of steel slag aggregate concrete using an artificial intelligence-based approach	AWOYERA ET AL.	Artigo	2021	Nigéria	Incluso

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
58	concrete using an artificial intelligence-based approach	AL-NEGHEIMISH ET AL.	Artigo	1997	Arábia Saudita	Incluso
59	Experimental study on steel slag and slag replacing sand in concrete	WANG ET AL.	Artigo	2008	China	O artigo não distingue quando a escória de aciaria é utilizada como adição ao cimento e quando é utilizada como agregado, o que inviabiliza a extração e análise dos dados.
60	Experimental investigation of coarse aggregate with steel slag in concrete	SUBRAMANI AND RAVI	Artigo	2015	Índia	O foco do trabalho é a análise com adições de resíduos de vidro no cimento (fora do escopo da proposta).
61	Effect of high temperature on properties of steel slag aggregate concrete	NETINGER ET AL.	Artigo	2013	Croácia	A resistência à compressão é avaliada após a exposição do concreto a altas temperaturas (fora do escopo da Proposta).
62	The setting behavior, mechanical properties and drying shrinkage of ternary blended concrete containing granite quarry dust and processed steel slag aggregate	LIM ET AL.	Artigo	2019	Malásia	Todos os traços são de adições de ggbfs ao cimento (fora do escopo da proposta).
63	Influence of classified steel slag with particle sizes smaller than 20 µm on the properties of cement and concrete	QIANG ET AL.	Artigo	2016	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
64	Effect of blended steel slag-GBFS mineral admixture on hydration and strength of cement	QIANG ET AL.	Artigo	2012	China	Escória de aciaria como adição mineral em argamassas (fora do escopo da proposta).
65	Steel slag as a substitute for natural aggregate in the production of concrete	VÁCLAVÍK ET AL.	Artigo	2016	República Tcheca	Valores iguais ao outro artigo publicado pelo Mesmo autor.

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
66	Long-term properties of concrete containing ground granulated blast furnace slag and steel slag	LIU ET AL.	Artigo	2014	China	Escória de aciaria como adição mineral (fora do escopo da proposta)
67	Influence of environmental conditions on concrete manufactured with recycled and steel slag aggregates at early ages and long term	APARICIO ET AL.	Artigo	2020	Espanha	Incluso.
68	Steel slag and its applications in cement and concrete technology: A review	GENCEL ET AL.	Artigo	2021	Turquia	Escória de aciaria como adição mineral (fora do escopo da proposta).o artigo faz apenas uma revisão sobre o assunto, não possuindo os dados necessários.
69	Effect of coarse aggregate quality on the mechanical properties of high strength concrete	BESHR ET AL.	Artigo	2003	Arábia Saudita	Não é fornecida a relação dos agregados para com o cimento, inviabilizando a extração dos dados Necessários.
70	Study on concrete using steel slag as coarse aggregate replacement and ecosand as fine aggregate replacement	CHINNARAJU ET AL.	Artigo	2013	Índia	Concreto de escória de aciaria com aparência e massa específica muito distinta dos outros trabalhos. Massa específica: 2,61 g/cm ³ (considerado fora do escopo da proposta).
71	Steel slag to improve the high strength of concrete	PALANISAMY ET AL.	Artigo	2015	Índia	Concreto para pavimentação (fora do escopo). Escória de aciaria como adição mineral (fora do escopo).
72	Utilization of electric arc furnace slag as aggregates in concrete—environmental issue	ALIZADEH ET AL.	Artigo	2003	Romênia	Não aborda teste de resistência à compressão.

7.2.2 Fonte: Scopus

Tabela 14 - Fontes adotadas para elaboração das tabelas – resultados do Scopus . Fonte: autor

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
73	Effect of surface-treated energy optimized furnace steel slag as coarse aggregate in the performance of concrete under corrosive environment	MALATHY ET AL.	Artigo	2021	Índia	
74	Flexural performance of reinforced concrete beams made by using recycled block aggregates and fibers	TAWFEEQ ET AL.	Artigo	2021	Omã	Escória de alto forno (fora do escopo da proposta).
75	Research on Basic Mechanical Properties of Large Scale Thermal Steel Slag Cement Concrete	YANG ET AL.	Artigo	2021	China	Não fornece dados suficientes para o cálculo do consumo de cimento.
76	Sustainable Recycling of Electric Arc Furnace Steel Slag as Aggregate in Concrete: Effects on the Environmental and Technical Performance	DIOTTI ET AL.	Artigo	2021	Itália	
77	A Novel Approach for Predicting the Compressive and Flexural Strength of Steel Slag Mixed Concrete Using Feed-Forward Neural Network - PP 475 - 486	GUPTA AND SACHDEVA	Artigo	2021	Índia	Concreto para pavimentação (fora do escopo). Escória de aciaria como adição mineral (fora do escopo).
78	Numerical Simulation of Basic Properties of Full-Steel Slag Aggregate Concrete	BIAN, Z. ET AL.	Artigo	2021	China	
79	The effect of coarse aggregate characteristics on the shear behavior of reinforced concrete slender beams	ALQARNI ET AL.	Artigo	2020	Arábia Saudita	
80	Combined effects of supplementary cementitious materials (silica fume, GGBS, fly ash and rice husk ash) and steel fiber on the hardened properties of recycled aggregate concrete	QURESHI ET AL.	Artigo	2020		Possui agregados de concreto reciclado em todos os traços (fora do escopo da proposta).

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
81	Sustainability Potential Evaluation of Concrete with Steel Slag Aggregates by the LCA Method	VLÁCLAVÍK ET AL.	Artigo	2020	República Tcheca	
82	A sustainable solution for ceramic and steel wastes in Self-consolidating, high-performance concrete	SOLEIMANI ET AL.	Artigo	2020	Austrália	Possui resíduos de cerâmica como agregado (fora do escopo da proposta).
83	Preparation, microstructure and property of carbonated artificial steel slag aggregate used in concrete	MO L. ET AL.	Artigo	2020	China	A escória de aciaria é artificialmente preparada com a adição de cimento e cinzas volantes (fora do escopo).
84	Mechanical performance study of pervious concrete using steel slag aggregate through laboratory tests and numerical simulation	WANG, G. ET AL.	Artigo	2020	China	Concreto permeável (fora do escopo da proposta).
85	Valorization of converter steel slag into eco-friendly ultra-high performance concrete by ambient CO2 pre-treatment	LIU, G. ET AL.	Artigo	2021	China	Escória de aciaria como adição mineral (fora do escopo da proposta).
86	Application of the response surface method to optimize alkali activated cements based on low-reactivity ladle furnace slag	PINHEIRO, C. ET AL.	Artigo	2020	Portugal	Otimização de cimentos alkali ativados (fora do escopo da proposta)
87	Effects of Steelmaking Slag and Moisture on Electrical Properties of Concrete	Hong, S. ET AL.	Artigo	2020	Coreia do Sul	Escória de aciaria como adição mineral (fora do escopo da proposta).
88	Enhancement of Mechanical Properties and Porosity of Concrete Using Steel Slag Coarse Aggregate	MAIAH, M. J. ET AL.	Artigo	2020	Bangladesh	Agregado graúdo de argila queimada e com massa específica bastante distinta dos dados usuais - burnt clay brick (fora do escopo da proposta).
89	Components of steel slag in acid-contaminated porous concrete	TONAPA S. R. ET AL.	Artigo	2020	Indonésia	A pesquisa utiliza escória de aciaria como constituinte de concreto poroso em contato direto com ácido sulfúrico e cloretos (fora do escopo da proposta).

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
90	Compressive Strength, Chloride Ion Penetrability, and Carbonation Characteristic of Concrete with Mixed Slag Aggregate	CHOI S., ET AL.	Artigo	2020	Coreia do Sul	Adição mineral constituinte por uma mistura de escória de alto forno e escória de ferro-níquel (fora do escopo da Proposta).
91	Recycling steel slag from municipal wastewater treatment plants into concrete applications – A step towards circular economy	ROYCHAND, R. ET AL.	Artigo	2020	Austrália	
92	Design Method for Optimizing Geopolymer Concrete Proportions Utilising Entirely Steel Slag Aggregates pp 459-464	VAN DAO, D. AND TRINH ET AL.	Artigo	2020	Vietnã	Concreto geopolimérico (fora do escopo da proposta).
93	Performance of Steel Slag as a Partial Replacement Fine Aggregate Incorporating Superplasticizer pp 151-160	VASUDEVAN G.	Artigo	2020	Malásia	O trabalho não menciona os traços utilizados, quantidades ou Consumo.
94	Strength and durability study of concrete using Precious Slag Balls	MALLICK, J. ET AL.	Artigo	2020	Índia	Concreto com "precious slag ball", um material inovador produzido a parte do rápido esfriamento da escória (fora do escopo da proposta).
95	Mechanical and durability properties of concrete with coarse recycled aggregate produced with electric arc furnace slag concrete	TAMAYO, P. ET A.	Artigo	2020	Espanha	Concreto com agregados reciclados de concreto de escória de aciaria (fora do escopo da proposta)
96	Studies on high performance alkali activated slag concrete mixes subjected to aggressive environments and sustained elevated temperatures	MANJUNATH, R. ET AL.	Artigo	2019	Índia	Concreto autoadensável de alta performance com escória álcali ativada - HPAASC (fora do escopo da Proposta).
97	High Strength Flowable Alkali Activated Slag Concrete Mixes produced using industrial wastes	MANJUNATH, R. AND NARASIMHAN, M. C.	Artigo	2019	Índia	Mistura de concreto de escória álcali ativada (fora do escopo da proposta).

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
98	Performance of sustainable high strength concrete with basic oxygen steel-making (BOS) slag and nano-silica	ZAREEI, S. A. ET AL.	Artigo	2019	Irã	Escória de aciaria como adição mineral (fora do escopo da proposta).
99	Comparing Properties of Concrete Containing Electric Arc Furnace Slag and Granulated Blast Furnace Slag	LEE, J. Y. ET AL.	Artigo	2019	Canadá	Escória de aciaria como adição mineral (fora do escopo da proposta).
100	Improvements in aggregate-paste interface by the hydration of steelmaking waste in concretes and mortars	MINANO, I. ET AL.	Artigo	2019	Espanha	Concreto de escória de alto forno (fora do escopo da proposta).
101	Performance of steel-making slag concrete reinforced with fibers	ORTEGA- LÓPEZ V., ET AL.	Artigo	2017	Espanha	Há adições de fibras metálicas e fibras sintéticas em todas as misturas. (fora do escopo da proposta).
102	Research experiences on the reuse of industrial waste for concrete production	ABBÀ, A. ET AL.	Artigo	2017	Itália	Não diferencia os agregados entre graúdos e miúdos. Além disso, resistência final de 12,7 mpa (fora do escopo da proposta).
103	High-Performance Concrete Incorporating Locally Available Industrial By-Products	SERDAR, M. ET AL.	Artigo	2017	Croácia	Não possui escória de aciaria.
104	Evaluation of the use of steelmaking slag as an aggregate in concrete mix: A factorial design approach	ALJBOUR, S. H. ET AL.	Artigo	2017	Sérvia	
105	Electric Arc Furnace Slag as Coarse Recycled Aggregate for Concrete Production	FALESCHINI, F. ET AL.	Artigo	2016	Itália	
106	Engineering properties of self-compacting concrete containing stainless steel slags	SHEEN, Y. N. ET AL.	Artigo	2016	Taiwan	Concreto autoadensável (fora do escopo da Proposta).
107	Electric arc furnace slag and its use in hydraulic concrete	ARRIBAS, I. ET AL.	Artigo	2015	Espanha	Os detalhes das dosagens se encontram no outro artigo publicado pelo mesmo autor.

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
108	Study on concrete by replacing coarse aggregate with steel slag and cement by Flyash	PADMAPRIYA, R. ET AL.	Artigo	2015	Índa	Não possui nenhum dado de dosagem ou consumo, apenas porcentagem de substituição.

7.2.3 Fonte: Web of Science

Tabela 15 - Fontes adotadas para elaboração das tabelas – resultados do Web of Science. Fonte: autor

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
109	Influence of steel slag on the properties of alkali-activated fly ash and blast-furnace slag based fiber reinforced composites	ZHAO, Y. ET AL.	Artigo	2020	China	Concretos de escória de aciaria com cinza volante álcali ativada. Compósitos reforçados de fibras álcali ativadas - ss- aafrcs - fibras de polietileno e adições de Na ₂ SiO ₃ (fora do escopo da proposta)
110	Engineering and gamma-ray attenuation properties of steel furnace slag heavyweight concrete with nano calcium carbonate and silica	KHALAF, M. A. ET AL.	Artigo	2020	Malásia	
111	Assessment of Steel Slag and Steel Fiber to Control Electromagnetic Shielding in High- Strength Concrete	YUAN, T. F. ET AL.	Artigo	2020	Coreia do Sul	Escória de aciaria como adição mineral (fora do escopo da proposta).
112	Triaxial Compression Performance Research of Steel Slag Concrete on the Unified Strength Theory	DENG, Z. ET AL.	Artigo	2020	China	Ensaio de compressão triaxial - metodologia diferente para obtenção da resistência à compressão (fora do escopo).
113	Application of Metallurgical Steel Slag Infoamed Concrete	ZHANG, L. F. ET AL.	Artigo	2020	China	Concreto de espuma (fora do escopo da proposta)
114	Quantitative evaluation of interfacial transition zone of sustainable concrete with recycled and steel slag as aggregate	WU, K. ET AL.	Artigo	2020	China	O artigo não distingue quando a escória de aciaria é utilizada como adição ao cimento e quando é utilizada como agregado

#	Título	Autor(es)	Tipo	Ano	País	Justificativa para inclusão / exclusão
115	Recurrent neural network-based prediction of compressive and flexural strength of steel slag mixed concrete	GUPTA AND SACHDEVA	Artigo	2020	Índia	Escória de aciaria como adição mineral (fora do escopo da proposta).
116	The study of properties and behavior of self compacting concrete containing Electric Arc Furnace Slag (EAFS) as aggregate	SANTAMARÍA, A. ET AL.	Artigo	2019	Espanha	Concreto autoadensável (fora do escopo da proposta).
117	Laboratory investigation of carbonated BOF slag used as partial replacement of natural aggregate in cement mortars	BODOR, M. ET AL.	Artigo	2016	Bélgica	Análise de argamassas (fora do escopo da proposta).
118	The use of steelmaking slags and fly ash in structural mortars	SANTAMARÍA, A. ET AL.	Artigo	2016	Espanha	Análise de argamassas estruturais (fora do escopo da proposta).

7.2.4 Referência dos Artigos do Banco de Dados da Literatura

ABU-EISHAH, S. I.; EL-DIEB, A. S.; BEDIR, M. S. Performance of concrete mixtures made with electric arc furnace (EAF) steel slag aggregate produced in the Arabian Gulf region. **Construction and Building Materials**, Arab Emirates, v. 34, p. 249–256, March 2012.

AI-NEGHEIMISH, A. I.; AI-SUGAIR, F. H.; AI-ZAID, R. Z. Utilization of Local Steelmaking Slag in Concrete. **King Saud University**, Saudi Arabia, v. 9, p. 39-55, 1997.

ALJBOUR, S. H.; TARAWNEH, S. A.; AL-HARAHSEH, A. M. Evaluation Of The Use Of Steelmaking Slag As An Aggregate In Concrete Mix: A Factorial Design Approach. **Chemical Industry & Chemical Engineering Quarterly**, Jordan, v. 23, 2017.

ALQARNI, A. S. et al. The effect of coarse aggregate characteristics on the shear behavior of reinforced concrete slender beams. **Construction and Building Materials**, Saudi Arabia, v. 264, August 2020.

ANASTASIOU, E.; FILIKAS, K. G.; STEFANIDOU, M. Utilization of Fine Recycled Aggregates in Concrete with Fly Ash and Steel Slag. **Construction and Building Materials**, Greece, v. 50, p. 154–161, 2014.

ANDRADE, H. D. Carbonatação em Concreto de Escória de Aciaria. **Universidade Federal de Ouro Preto**, Ouro Preto, Brasil, 2018.

APARICIO, S.; HERNÁNDEZ, M. G.; ANAYA, J. J. Influence of environmental conditions on concrete manufactured with recycled and steel slag aggregates at early ages and long term. **Construction and Building Materials**, Madrid, Spain, v. 249 , March 2020.

ARRIBAS, I. et al. Electric arc furnace slag and its use in hydraulic concrete. **Construction and Building Materials** , Spain, v. 90 , p. 68–79, May 2015.

AWOYERA, P. O. et al. A new formulation for strength characteristics of steel slag aggregate concrete using an artificial intelligence-based approach. **Computers and Concrete**, Nigerian, v. 27, p. 333-341, March 2021.

BIAN, Z. et al. Numerical Simulation of Basic Properties of Full-Steel Slag Aggregate Concrete. **Advances in Civil Engineering**, China, v. 2021, p. 17, January 2021.

BISKRI, Y. et al. Mechanical and durability characteristics of High Performance Concrete containing steel slag and crystalized slag as aggregates. **Construction and Building Materials**, Algeria, v. 150, p. 167–178, May 2017.

COSTA, L. C. B. Desempenho de concretos de escória de aciaria frente a ataque de cloretos. **Universidade Federal de Ouro Preto**, Ouro Preto, Brasil, 2019.

DEVI, V. S.; GNANAVEL, B. K. Properties of concrete manufactured using steel slag. **Procedia Engineering**, India, v. 97, p. 95-104, 2014.

DIOTTI, A. et al. Sustainable Recycling of Electric Arc Furnace Steel Slag as Aggregate in Concrete: Effects on the Environmental and Technical Performance. **Environmental and Technical Performance. Sustainability** , v. 13, p. 521, January 2021.

FALESCHINI, F. et al. Electric Arc Furnace Slag as Coarse Recycled Aggregate for Concrete Production. **Journal of Sustainable Metallurgy** , Italy, v. 2, p. 44–50, March 2016.

FARIA, R. A. F. Contribuição ao Estudo das Propriedades Mecânicas. **Universidade Federal de Goiás**, Goiânia, 2007.

GUO, Y. et al. Utilization of unprocessed steel slag as fine aggregate in normal- and high-strength concrete. **Construction and Building Materials**, China, v. 204 , p. 41–49, 2019.

HUANG, X. et al. On the use of blast furnace slag and steel slag in the preparation of green artificial reef concrete. **Construction and Building Materials** , China, v. 112, p. 241–246, February 2016.

KHALAF, M. A. et al. Engineering and gamma-ray attenuation properties of steel furnace slag heavyweight concrete with nano calcium carbonate and silica. **Construction and Building Materials**, Malasya, v. 267, January 2021.

MALATHY, R. et al. Effect of surface-treated energy optimized furnace steel slag as coarse aggregate in the performance of concrete under corrosive environment. **Construction and Building Materials**, India, v. 284 , February 2021.

NETINGER, I.; BJEGOVIC, D.; VRHOVAC, G. Utilisation of steel slag as an aggregate in concrete. **Materials and Structures**, Croatia, v. 44, p. 1565–1575, 2011.

PANG, B.; ZHOU, Z.; XU, H. Utilization of carbonated and granulated steel slag aggregate in concrete. **Construction and Building Materials**, China, v. 84, p. 454–467, March 2015.

PAPACHRISTOFOROU, M.; ANASTASIOU, E. K.; PAPAYIANNI, I. Durability of steel fiber reinforced concrete with coarse steel slag aggregates including performance at elevated temperatures. **Construction and Building Materials**, Greece, v. 262, August 2020.

QASRAWI, H.; SHALAB, F.; ASI, I. Use of low CaO unprocessed steel slag in concrete as fine aggregate. **Construction and Building Materials**, Jordan, v. 23, p. 1118–1125, 2009.

ROYCHAND, R. et al. Recycling steel slag from municipal wastewater treatment plants into concrete applications – A step towards circular economy. **Resources, Conservation & Recycling**, Australia, v. 152, 2020.

SAXENA, S.; TEMBHURKAR, A. R. Impact of use of steel slag as coarse aggregate and wastewater on fresh and hardened properties of concrete. **Construction and Building Materials**, India, v. 165, p. 126–137, January 2018.

SEZER, G. İ.; GÜLDEREN, M. Usage of steel slag in concrete as fine and/or coarse aggregate. **Indian Journal of Engineering & Materials Sciences**, Turkey, v. 22, p. 339-344, June 2015.

SOUZA, B. P. D. et al. Caracterização Físico-Química de Agregados de Escória de Aciaria LD Pós-Processada para Concretos Sustentáveis. **22º CBECiMat - Congresso Brasileiro de Engenharia e Ciência dos Materiais**, Natal, RN, Brasil, Novembro 2016.

STIEF, J. N. D. P.; MAIA, N. D. S.; PEIXOTO, R. A. F. Determinação experimental do Módulo de Elasticidade do Concreto Convencional e com Agregados de Escória de Aciaria. **Educação e Tecnologia**, Brasil, v. 14, n. 2, p. 22-77, Agosto 2009.

ÁCLAVÍK, V. et al. Sustainability Potential Evaluation of Concrete with Steel Slag Aggregates by the LCA Method. **MDPI Journal, Sustainability 2020**, Czech Republic, v. 12, November 2020.

YU, X. et al. Performance of Concrete Made with Steel Slag And Waste Glass. **Construction and Building Materials** , Australia, v. 114 , p. 737–746, 2016.

ZAGO, S. D. C. Avaliação da durabilidade do concreto da construção civil com a utilização de agregados de escória de aciaria LD. **Universidade de São Paulo - Escola de Engenharia de Lorena**, Lorena, Brasil,

7.3 Banco de dados elaborado pelo autor

O Banco de dados elaborado a partir de dados da literatura se encontra na Tabela 16 e também pode ser encontrado na íntegra no Github do CIDENG: <https://github.com/cidengcnpg> . O autor solicita que, caso o banco de dados seja utilizado, que se cite o artigo “Predicting the compressive strength of steelmaking slag concrete with machine learning - considerations on developing a mix design tool”.

Tabela 16 – Banco de Dados Completo. Fonte: autor

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolânicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura	
1	CP II F-32	617,00	0,00	524,45	542,96	445,78	0,30	185,10	52,51	1,10	0	0	0	28	52,84	52,84	FARIA, 2007	Brasil	cilíndricos - 100x200 mm - NBR 5738:1984	NBR 5739:1994	
2		617,00	0,00	1048,90	542,96	0,00	0,30	185,10	52,51	1,10	0	0	0	0	28	56,02					56,02
3		369,00	0,00	479,70	560,88	623,61	0,52	191,88	49,22	0,00	0	0	0	0	3	17,19					17,19
4		369,00	0,00	959,40	560,88	0,00	0,52	191,88	49,22	0,00	0	0	0	0	3	17,63					17,63
5		369,00	0,00	479,70	560,88	623,61	0,52	191,88	49,22	0,00	0	0	0	0	7	17,06					17,06
6		369,00	0,00	959,40	560,88	0,00	0,52	191,88	49,22	0,00	0	0	0	0	7	20,63					20,63
7		369,00	0,00	479,70	560,88	623,61	0,52	191,88	49,22	0,00	0	0	0	0	28	19,61					19,61
8		369,00	0,00	959,40	560,88	0,00	0,52	191,88	49,22	0,00	0	0	0	0	28	23,55					23,55
9		265,00	0,00	614,80	866,55	1426,34	0,80	212,00	47,92	0,00	0	0	0	0	3	7,77					7,77
10		265,00	0,00	1229,60	866,55	0,00	0,80	212,00	47,92	0,00	0	0	0	0	3	4,46					4,46
11		265,00	0,00	614,80	866,55	1426,34	0,80	212,00	47,92	0,00	0	0	0	0	7	8,10					8,10
12		265,00	0,00	1229,60	866,55	0,00	0,80	212,00	47,92	0,00	0	0	0	0	7	5,93					5,93
13		265,00	0,00	614,80	866,55	1426,34	0,80	212,00	47,92	0,00	0	0	0	0	28	11,60					11,60
14		265,00	0,00	1229,60	866,55	0,00	0,80	212,00	47,92	0,00	0	0	0	0	28	12,54					12,54
15		374,61	973,98	1311,13	0,00	0,00	0,64	239,75	50,70	0,00	0	0	0	0	28	21,90					21,90
16		458,13	925,42	1328,57	0,00	0,00	0,48	219,90	51,01	0,00	0	0	0	0	28	40,70					40,70
17		548,15	800,30	1266,23	0,00	0,00	0,44	241,19	51,57	0,00	0	0	0	0	28	45,17					45,17
18		260,97	1466,65	1239,61	0,00	0,00	0,64	167,02	58,22	1,00	0	0	0	0	28	31,00					31,00
19	395,07	1315,58	1145,70	0,00	0,00	0,48	189,63	59,89	1,00	0	0	0	0	28	45,27	43,11					
20	415,49	1292,16	1167,51	0,00	0,00	0,44	182,81	59,39	1,00	0	0	0	0	28	59,67	56,83					
21	362,51	953,40	1250,66	0,00	0,00	0,64	232,01	51,27	0,00	0	0	0	0	28	26,45	25,19					
22	442,56	893,97	1283,42	0,00	0,00	0,48	212,43	51,01	0,00	0	0	0	0	28	39,67	37,78					
23	507,39	629,16	1425,76	0,00	0,00	0,44	223,25	44,36	0,00	0	0	0	0	28	48,10	45,81					
24	314,00	1296,83	1083,31	0,00	0,00	0,64	200,96	59,79	1,00	0	0	0	0	28	31,37	29,88					
25	379,98	1265,32	1101,93	0,00	0,00	0,48	182,39	59,89	1,00	0	0	0	0	28	43,90	41,81					
26	489,33	1110,77	1017,80	0,00	0,00	0,44	215,30	61,12	1,00	0	0	0	0	28	52,63	50,12					
27	310,00	1361,16	1161,31	0,00	0,00	0,62	201,82	59,00	0,70	15,51	0	0	0	42	50,97	48,54					
28	310,00	1345,25	1150,26	0,00	0,00	0,62	206,99	59,00	0,70	23,86	0	0	0	42	53,40	50,86					
29	310,00	1330,80	1140,21	0,00	0,00	0,62	213,46	59,00	0,30	34,29	0	0	0	42	49,30	46,95					
30	310,00	1281,23	1105,77	0,00	0,00	0,62	229,10	59,00	0,25	60	0	0	0	42	30,80	29,33					
31	450,00	1361,16	1161,31	0,00	0,00	0,44	207,91	59,00	0,48	22,52	0	0	0	42	60,37	57,50					
32	450,00	1345,25	1150,26	0,00	0,00	0,44	213,24	59,00	0,58	34,64	0	0	0	42	59,10	56,29					
33	450,00	1330,80	1140,21	0,00	0,00	0,44	219,90	59,00	0,33	49,77	0	0	0	42	64,00	60,95					
34	450,00	1281,23	1105,77	0,00	0,00	0,44	236,62	59,00	0,20	87,10	0	0	0	42	58,70	55,90					
35	354,32	1180,44	1133,02	0,00	0,00	0,60	212,59	55,05	0,00	0,00	0	0	0	3	27,00	25,71					
36	354,32	1162,65	1120,65	0,00	0,00	0,60	212,59	55,05	0,00	0,00	0	0	0	7	34,00	32,38					
37	354,32	1147,78	1110,32	0,00	0,00	0,60	212,59	55,05	0,00	0,00	0	0	0	28	43,00	40,95					
38	444,25	1090,43	1070,47	0,00	0,00	0,55	288,77	53,42	0,00	0,00	0	0	0	3	31,10	29,62					
39	444,25	910,72	1181,72	0,00	0,00	0,55	288,77	53,42	0,00	0	0	0	0	7	34,04	34,04					
40	444,25	910,72	1181,72	0,00	0,00	0,55	288,77	53,42	0,00	0	0	0	0	28	35,43	35,43					
41	678,21	705,34	1139,39	0,00	0,00	0,36	311,98	54,84	0,00	0	0	0	0	3	41,55	41,55					
42	678,21	705,34	1139,39	0,00	0,00	0,36	311,98	54,84	0,00	0	0	0	0	7	45,39	43,23					
43	678,21	705,34	1139,39	0,00	0,00	0,36	311,98	54,84	0,00	0	0	0	0	28	49,12	46,78					
44	345,29	62,43	0,00	561,86	0,00	0,55	189,91	42,17	0,00	0	0	0	0	28	19,56	18,63					
45	346,02	125,12	0,00	500,48	0,00	0,55	190,31	42,17	0,00	0	0	0	0	28	20,10	19,14					
46	346,73	188,07	0,00	438,83	0,00	0,55	190,70	42,17	0,00	0	0	0	0	28	20,78	19,79					
47	347,44	251,27	0,00	376,90	0,00	0,55	191,09	42,17	0,00	0	0	0	0	28	21,67	20,64					
48	348,14	314,72	0,00	314,72	0,00	0,55	191,48	42,17	0,00	0	0	0	0	28	19,32	16,66					
49	Ordinary Portland Cement of 53grade	350,50	0,00	134,94	633,70	467,57	0,55	192,77	42,17	0,00	0	0	0	28	22,80	19,66					
50		356,22	0,00	274,29	644,05	844,82	0,55	195,92	42,17	0,00	0	0	0	28	24,75	21,34					
51		361,73	0,00	417,80	654,02	1125,98	0,55	198,95	42,17	0,00	0	0	0	28	28,33	24,42					
52		367,05	0,00	565,25	663,62	1305,73	0,55	201,88	42,17	0,00	0	0	0	28	27,02	23,29					
53		372,17	0,00	716,42	672,88	1379,12	0,55	204,69	42,17	0,00	0	0	0	28	25,06	21,60					

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolánicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura
54		400,00	0,00	1145,00	864,00	0,00	0,43	172,00	52,47	0,80	0	0	0	2	39,00	33,62				
55		400,00	0,00	1145,00	864,00	0,00	0,43	172,00	52,47	0,80	0	0	0	28	57,00	49,14				
56		400,00	0,00	1145,00	864,00	0,00	0,43	172,00	52,47	0,80	0	0	0	56	69,00	59,48				
57		400,00	0,00	1145,00	864,00	0,00	0,43	172,00	52,47	0,80	0	0	0	90	66,00	56,90				
58		400,00	0,00	1115,00	841,00	0,00	0,43	172,00	52,67	0,80	0	0	0	2	32,50	28,02				
59		400,00	0,00	1115,00	841,00	0,00	0,43	172,00	52,67	0,80	0	0	0	28	48,00	41,38				
60		400,00	0,00	1115,00	841,00	0,00	0,43	172,00	52,67	0,80	0	0	0	56	49,50	42,67				
61	CEM I 52,5 N	400,00	0,00	1115,00	841,00	0,00	0,43	172,00	52,67	0,80	0	0	0	90	59,50	51,29	NETINGER ET AL., 2011	Croácia	Cubos - 150x150x150 mm	HRN EN 12390-3:2002
62		410,07	0,00	1371,69	656,11	0,00	0,55	220,00	43,73	0,00	0	0	0	28	32,50	28,02				
63		425,07	0,00	1449,27	730,69	0,00	0,40	168,00	44,37	0,31	0	0	0	28	48,00	41,38				
64		424,58	999,81	0,00	0,00	0,00	0,40	168,00	56,54	0,37	0	0	0	28	59,50	51,29				
65		349,85	0,00	1113,55	1009,57	0,00	0,50	137,00	54,97	0,20	0	0	0	28	63,00	54,31				
66		343,00	80,94	0,00	572,40	0,00	0,59	202,00	46,40	0,00	0	0	0	90	32,96	32,96				
67		343,00	161,89	0,00	508,80	0,00	0,59	202,00	46,83	0,00	0	0	0	90	33,25	33,25				
68	Ordinary Portland Cement	343,00	242,83	0,00	445,20	0,00	0,59	202,00	47,25	0,00	0	0	0	90	31,63	31,63	GUO ET AL., 2019	China	Cilíndricos - 150x300 mm	GB 50081-2019
69		343,00	323,77	0,00	381,60	0,00	0,59	202,00	47,67	0,20	0	0	0	90	30,75	26,51				
70		343,00	80,94	0,00	572,40	1151,00	0,59	202,00	48,48	0,00	0	0	0	90	29,52	30,43				
71		343,00	161,89	0,00	508,80	1151,00	0,59	202,00	49,27	0,00	0	0	0	90	35,07	36,15				
72		343,00	242,83	0,00	445,20	1151,00	0,59	202,00	50,03	0,00	0	0	0	90	34,55	35,62				
73		343,00	323,77	0,00	381,60	1151,00	0,35	164,00	47,68	0,86	0	0	0	90	64,17	66,15				
74		343,00	485,66	0,00	254,40	1151,00	0,35	164,00	48,10	0,86	0	0	0	90	70,76	72,95				
75		343,00	647,55	0,00	127,20	1151,00	0,35	164,00	48,51	0,86	0	0	0	90	72,67	74,92				
76		343,00	809,44	0,00	0,00	1151,00	0,35	164,00	48,91	0,86	0	0	0	90	67,35	69,43				
77		343,00	73,60	0,00	520,47	1028,07	0,35	164,00	49,70	0,86	0	0	0	90	69,82	71,98				
78		343,00	147,20	0,00	462,64	1028,07	0,35	164,00	50,47	0,86	0	0	0	90	71,54	73,75				
79		343,00	220,80	0,00	404,81	1028,07	0,35	164,00	51,21	0,86	0	0	0	90	74,23	76,53				
80		343,00	294,40	0,00	346,98	1028,07	0,42	158,00	57,67	0,86	0	0	0	3	13,70	14,12				
81		343,00	441,60	0,00	231,32	1028,07	0,42	158,00	57,67	0,86	0	0	0	7	26,70	27,53				
82	343,00	588,80	0,00	115,66	1028,07	0,42	158,00	57,67	0,86	0	0	0	28	60,50	62,37					
83	343,00	736,00	0,00	0,00	1028,07	0,42	158,00	57,67	0,86	0	0	0	60	60,20	62,06					
84	CEM I 42,5R Normal Portland Cement	375,00	1456,27	1344,26	0,00	0,00	0,42	158,00	47,64	3,00	0,00	0,00	0	3	13,70	10,79	PANG ET AL., 2015	China	Cubos - 100x100x100 mm	TS-EN 12390-3
85		375,00	1456,27	1344,26	0,00	0,00	0,42	158,00	47,64	3,00	0,00	0,00	0	7	26,70	21,02				
86		375,00	1456,27	1344,26	0,00	0,00	0,42	158,00	47,64	3,00	0,00	0,00	0	28	60,50	47,64				
87		375,00	1456,27	1344,26	0,00	0,00	0,42	158,00	47,64	3,00	0,00	0,00	0	60	60,20	47,40				
88	CEM I 42,5R Normal Portland Cement	346,00	0,00	1331,00	865,00	0,00	0,40	139,00	48,19	3,47	0,00	0,00	0	3	46,30	39,91	SEZER AND GULDERE N, 2015	Turquia	Cubos - 150x150x150 mm	TS-EN 12390-3
89		346,00	0,00	1331,00	865,00	0,00	0,40	139,00	48,19	3,47	0,00	0,00	0	7	48,90	42,16				
90		346,00	0,00	1331,00	865,00	0,00	0,40	139,00	48,19	3,47	0,00	0,00	0	28	54,80	47,24				
91		346,00	0,00	1331,00	865,00	0,00	0,40	139,00	48,19	3,47	0,00	0,00	0	90	61,50	53,02				
92		354,00	0,00	1262,00	820,00	0,00	0,55	195,00	48,81	1,38	0,00	0,00	0	3	33,30	28,71				
93		354,00	0,00	1262,00	820,00	0,00	0,55	195,00	48,81	1,38	0,00	0,00	0	7	33,80	29,14				
94		354,00	0,00	1262,00	820,00	0,00	0,55	195,00	48,81	1,38	0,00	0,00	0	28	37,50	32,33				
95		354,00	0,00	1262,00	820,00	0,00	0,55	195,00	48,81	1,38	0,00	0,00	0	90	43,90	37,84				
96		360,00	0,00	1184,00	769,00	0,00	0,70	252,00	48,08	0,00	0,00	0,00	0	3	20,40	17,59				
97		360,00	0,00	1184,00	769,00	0,00	0,70	252,00	48,08	0,00	0,00	0,00	0	7	21,70	18,71				
98		360,00	0,00	1184,00	769,00	0,00	0,70	252,00	48,08	0,00	0,00	0,00	0	28	26,80	23,10				
99		360,00	0,00	1184,00	769,00	0,00	0,70	252,00	48,08	0,00	0,00	0,00	0	90	30,10	25,95				
100		318,00	747,00	0,00	0,00	1150,00	0,40	127,00	48,70	0,35	0,00	0,00	0	3	33,60	28,97				
101		318,00	747,00	0,00	0,00	1150,00	0,40	127,00	48,70	0,35	0,00	0,00	0	7	35,00	30,17				
102		318,00	747,00	0,00	0,00	1150,00	0,40	127,00	48,70	0,35	0,00	0,00	0	28	48,20	41,55				
103		318,00	747,00	0,00	0,00	1150,00	0,40	127,00	48,70	0,35	0,00	0,00	0	90	50,70	43,71				
104		334,00	731,00	0,00	0,00	1122,00	0,55	184,00	49,29	0,18	0,00	0,00	0	3	24,70	21,29				
105	334,00	731,00	0,00	0,00	1122,00	0,55	184,00	49,29	0,18	0,00	0,00	0	7	25,00	21,55					
106	334,00	731,00	0,00	0,00	1122,00	0,55	184,00	49,29	0,18	0,00	0,00	0	28	34,70	29,91					
107	334,00	731,00	0,00	0,00	1122,00	0,55	184,00	49,29	0,18	0,00	0,00	0	90	37,80	32,59					
108	345,00	694,00	0,00	0,00	1069,00	0,70	242,00	40,22	0,00	0,00	0,00	0	3	19,00	16,38					
109	345,00	694,00	0,00	0,00	1069,00	0,70	242,00	40,22	0,00	0,00	0,00	0	7	20,00	17,24					

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolânicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura
110		345,00	694,00	0,00	0,00	1069,00	0,70	242,00	40,22	0,00	0,00	0,00	0	28	25,30	21,81				
111		345,00	694,00	0,00	0,00	1069,00	0,70	242,00	40,22	0,00	0,00	0,00	0	90	26,40	22,76				
112		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	3	14,20	14,64				
113		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	7	20,80	21,44				
114		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	28	26,10	26,91				
115		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	90	31,60	32,58				
116		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	210	29,40	30,31				
117		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	3	15,00	15,46				
118		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	7	19,60	20,21				
119		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	28	20,70	21,34				
120		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	90	25,60	26,39				
121		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	210	27,60	28,45				
122		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	3	16,00	16,49				
123		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	40,22	0,00	0,00	0,00	0	7	17,70	18,25				
124		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	82,45	0,00	0,00	0,00	0	28	16,70	17,22				
125		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	83,09	0,00	0,00	0,00	0	90	18,40	18,97				
126		350,00	0,00	1583,00	715,00	0,00	0,62	217,00	47,80	0,00	0,00	0,00	0	210	17,30	17,84				
127		350,00	0,00	1583,00	715,00	0,00	0,42	147,00	48,51	0,02	0,00	0,00	0	7	34,80	35,88				
128		425,00	264,00	119,00	1237,00	291,00	0,43	183,00	47,80	1,00	0,00	0,00	0	28	53,70	46,29				
129	Type I Ordinary Portland Cement	425,00	1919,00	477,00	0,00	0,00	0,43	183,00	48,51	1,00	0,00	0,00	0	28	62,10	53,53	APARICIO ET AL., 2020	Espanha	Cubos - 150x150x150 mm	ASTM C39
130		400,00	0,00	620,00	297,00	1489,55	0,48	190,00	30,60	1,00	0,00	0,00	0	3	40,50	34,91				
131		400,00	0,00	620,00	297,00	1489,55	0,48	190,00	30,60	1,00	0,00	0,00	0	7	45,30	39,05				
132		400,00	0,00	620,00	297,00	1489,55	0,48	190,00	30,60	1,00	0,00	0,00	0	14	48,00	41,38				
133		400,00	0,00	620,00	297,00	1489,55	0,48	190,00	30,60	1,00	0,00	0,00	0	21	46,30	39,91				
134		400,00	0,00	620,00	297,00	961,00	0,48	190,00	30,60	1,00	0,00	0,00	0	3	40,50	34,91				
135		400,00	0,00	620,00	297,00	961,00	0,48	190,00	30,60	1,00	0,00	0,00	0	7	45,30	39,05				
136		400,00	0,00	620,00	297,00	961,00	0,48	190,00	30,60	1,00	0,00	0,00	0	14	48,00	41,38				
137		400,00	0,00	620,00	297,00	961,00	0,48	190,00	44,57	1,00	0,00	0,00	0	21	46,30	39,91				
138		400,00	0,00	620,00	297,00	961,00	0,48	190,00	44,57	1,00	0,00	0,00	0	28	50,60	43,62				
139		400,00	0,00	620,00	297,00	961,00	0,48	190,00	47,02	1,00	0,00	0,00	0	70	52,80	45,52				
140		400,00	0,00	620,00	297,00	961,00	0,48	190,00	49,95	1,00	0,00	0,00	0	90	52,30	45,09				
141		345,00	0,00	1195,00	616,00	0,00	0,58	200,00	52,88	0,00	0,00	0,00	0,00	28	34,50	27,17				
142		345,00	154,00	1195,00	462,00	0,00	0,58	200,00	64,12	0,00	0,00	0,00	0,00	28	36,50	28,74				
143		426,00	296,00	803,00	296,00	344,00	0,47	200,00	46,26	0,00	0,00	0,00	0,00	28	34,10	26,85				
144		526,00	420,00	435,00	140,00	653,00	0,38	200,00	48,61	0,00	0,00	0,00	0,00	28	34,50	27,17				
145		625,00	531,00	0,00	0,00	1030,00	0,32	200,00	51,50	0,00	0,00	0,00	0,00	28	44,30	34,88				
146		345,00	163,00	463,00	489,00	95,00	0,58	200,00	54,30	0,00	0,00	0,00	0,00	28	26,90	21,18				
147		345,00	326,00	0,00	326,00	1158,00	0,58	200,00	47,94	0,00	0,00	0,00	0,00	28	23,50	18,50				
148		426,00	470,00	1113,00	157,00	0,00	0,47	200,00	47,94	0,00	0,00	0,00	0,00	28	44,50	35,04				
149		526,00	593,00	1054,00	0,00	0,00	0,38	200,00	50,21	0,00	0,00	0,00	0,00	28	40,80	32,13				
150		625,00	0,00	699,00	562,00	300,00	0,32	200,00	52,99	0,00	0,00	0,00	0,00	28	60,60	47,72				
151		345,00	344,00	1122,00	344,00	0,00	0,58	200,00	55,74	0,00	0,00	0,00	0,00	28	33,70	26,54				
152		345,00	516,00	785,00	172,00	337,00	0,58	200,00	47,94	0,00	0,00	0,00	0,00	28	25,50	20,08				
153		426,00	660,00	431,00	0,00	646,00	0,47	200,00	47,94	0,00	0,00	0,00	0,00	28	20,30	15,98				
154		526,00	0,00	0,00	626,00	1022,00	0,38	200,00	50,21	0,00	0,00	0,00	0,00	28	32,10	25,28				
155		625,00	148,00	967,00	445,00	0,00	0,32	200,00	52,99	0,00	0,00	0,00	0,00	28	47,40	37,32				
156		345,00	516,00	0,00	172,00	1122,00	0,58	200,00	55,76	0,00	0,00	0,00	0,00	28	11,90	9,37				
157		345,00	688,00	1122,00	0,00	0,00	0,58	200,00	49,61	0,00	0,00	0,00	0,00	28	17,50	13,78				
158		426,00	0,00	1077,00	660,00	0,00	0,47	200,00	49,63	0,00	0,00	0,00	0,00	28	41,30	32,52				
159		526,00	157,00	715,00	469,00	307,00	0,38	200,00	51,85	0,00	0,00	0,00	0,00	28	45,50	35,83				
160		625,00	297,00	387,00	297,00	580,00	0,32	200,00	54,55	0,00	0,00	0,00	0,00	28	34,80	27,40				
161		345,00	724,00	760,00	0,00	326,00	0,58	200,00	57,17	0,00	0,00	0,00	0,00	28	21,50	16,93				
162		345,00	0,00	434,00	724,00	651,00	0,58	200,00	40,93	0,00	0,00	0,00	0,00	28	29,20	22,99				
163		426,00	175,00	0,00	521,00	1042,00	0,47	200,00	45,45	0,00	0,00	0,00	0,00	28	31,70	24,96				
164		526,00	330,00	988,00	330,00	0,00	0,38	200,00	45,45	0,00	0,00	0,00	0,00	28	26,10	20,55				
165		625,00	467,00	935,00	156,00	0,00	0,32	200,00	45,45	0,00	0,00	0,00	0,00	28	40,30	31,73				
128	Type I Ordinary Portland Cement	425,00	264,00	119,00	1237,00	291,00	0,43	183,00	47,80	1,00	0,00	0,00	0	28	53,70	46,29	APARICIO ET AL., 2020	Espanha	Cubos - 150x150x150 mm	ASTM C39
133	Ordinary Portland Cement (OPC)	400,00	0,00	620,00	297,00	961,00	0,48	190,00	30,60	1,00	0,00	0,00	0	3	40,50	34,91	DIOTTI ET AL., 2021	Itália	Cubos - 150x150x150 mm	EN 12390-3
154	Ordinary Cement	526,00	0,00	0,00	626,00	1022,00	0,38	200,00	50,21	0,00	0,00	0,00	0,00	28	32,10	25,28	BIAN, Z. ET AL., 2021	China	Cubos - 100x100x100 mm	GB/T 50081-2019

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolánicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura					
166	Ordinary Cement	500,00	0,00	1452,00	506,00	0,00	0,30	150,00	45,45	1,00	0,00	0,00	0,00	28	81,60	81,60	ALQARNI ET AL., 2020	Arábia Saudita	Cilindros 100x200 mm	ASTM C39					
167	Portland cement CEM I 42.5 R	350,00	0,00	1050,00	1400,00	1050,00	0,55	192,50	45,45	1,00	0,00	0,00	0,00	28	45,00	38,79	VLÁČLAVÍK ET AL., 2020	República Tcheca	Cubos - 150x150x150 mm	EN12390-3, (2009) e ISO 4012 (1994)					
168		350,00	0,00	1050,00	1400,00	1050,00	0,55	192,50	45,45	1,00	0,00	0,00	0,00	28	37,80	32,59									
169		350,00	0,00	1050,00	1400,00	1050,00	0,55	192,50	45,45	1,00	0,00	0,00	0,00	28	46,00	39,66									
170		350,00	0,00	1050,00	1400,00	1050,00	0,55	192,50	45,45	1,00	0,00	0,00	0,00	28	29,60	25,52									
171		350,00	0,00	2100,00	1400,00	0,00	0,55	192,50	39,30	1,00	0,00	0,00	0,00	28	39,50	34,05									
172		350,00	0,00	2100,00	1400,00	0,00	0,55	192,50	39,30	1,00	0,00	0,00	0,00	28	34,90	30,09									
173	Portland cement CEM	416,00	0,00	572,00	624,00	624,00	0,40	166,00	39,30	0,48	0,00	0,00	0,00	7	38,40	38,40	ROYCHAN D, R. ET AL.,	Austrália	Cilindros - 100 x 200 mm	AS1012.9.1, 2014					
174		416,00	0,00	572,00	624,00	624,00	0,40	166,00	39,30	0,48	0,00	0,00	0,00	28	61,70	61,70									
175	Ordinary Cement Portland CEM-1 42.5N	425,00	0,00	361,00	510,00	1083,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	3	24,40	21,03	ALJBOUR, S. H. ET AL., 2017	Sérvia	Cubos - 150x150x150 mm	ASTM C39					
176		425,00	0,00	361,00	510,00	1083,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	7	31,10	26,81									
177		425,00	0,00	361,00	510,00	1083,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	28	34,60	29,83									
178		425,00	0,00	638,00	510,00	806,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	3	22,40	19,31									
179		425,00	0,00	638,00	510,00	806,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	7	25,30	21,81									
180		425,00	0,00	638,00	510,00	806,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	28	41,10	35,43									
181		425,00	0,00	806,00	510,00	638,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	3	22,40	19,31									
182		425,00	0,00	806,00	510,00	638,00	0,60	255,00	39,30	0,00	0,00	0,00	0,00	7	31,10	26,81									
183		425,00	0,00	806,00	510,00	638,00	0,60	255,00	46,67	0,00	0,00	0,00	0,00	28	42,80	36,90									
184		425,00	0,00	1083,00	510,00	361,00	0,60	255,00	46,67	0,00	0,00	0,00	0,00	3	21,30	18,36									
185		425,00	0,00	1083,00	510,00	361,00	0,60	255,00	45,29	0,00	0,00	0,00	0,00	7	32,60	28,10									
186		425,00	0,00	1083,00	510,00	361,00	0,60	255,00	45,29	0,00	0,00	0,00	0,00	28	45,50	39,22									
187		400,00	0,00	1408,00	832,00	0,00	0,40	160,00	46,90	1,20	0,00	0,00	0,00	7	69,05	59,53									
188		Ordinary Cement Portland CEM-1 42.5N	400,00	0,00	1408,00	832,00	0,00	0,40	160,00	46,90	1,20	0,00	0,00	0,00	28	76,40					65,86	FALESCHI NI, F. ET AL., 2016	Itália	Cubos - 150x150x150 mm	EN 12390-4 (2000)
189	350,00		0,00	1476,00	872,00	0,00	0,40	140,00	31,87	1,20	0,00	0,00	0,00	7	60,60	52,24									
190	350,00		0,00	1476,00	872,00	0,00	0,40	140,00	31,87	1,20	0,00	0,00	0,00	28	73,90	63,71									
191	400,00		0,00	1370,00	810,00	0,00	0,40	184,00	30,52	1,20	60,00	0,00	0,00	7	54,60	47,07									
192	400,00		0,00	1370,00	810,00	0,00	0,40	184,00	30,52	1,20	60,00	0,00	0,00	28	65,00	56,03									
193	300,00		265,00	1208,00	0,00	0,00	0,69	207,00	47,15	3,60	0,00	0,00	815,00	28	55,00	56,70									
194	Portland CEM-1 52 5R	300,00	265,00	1208,00	0,00	0,00	0,69	207,00	47,15	3,60	0,00	0,00	815,00	90	62,80	64,74	ARRIBAS, I. ET AL., 2015	Espanha	Cilindros - 150 x 300 mm	EN 12390-6 (2010)					
195		300,00	293,00	1350,00	0,00	0,00	0,65	195,00	47,14	3,60	0,00	0,00	815,00	28	55,70	57,42									
196		300,00	293,00	1350,00	0,00	0,00	0,65	195,00	47,14	3,60	0,00	0,00	815,00	90	60,10	61,96									
197		303,00	191,00	0,00	574,00	1197,00	0,54	164,00	47,15	0,80	0,00	0,00	0,00	28	33,60	33,60									
198		303,00	191,00	0,00	574,00	1197,00	0,54	164,00	47,15	0,80	0,00	0,00	0,00	180	37,70	37,70									
199		CPV - ARI	305,00	384,00	0,00	384,00	1203,00	0,54	165,00	50,00	0,80	0,00	0,00	0,00	28	36,00					36,00	ZAGO, S. C., 2019	Brasil	Cilindros 100x200 mm	NBR 5738 (2015)
200			305,00	384,00	0,00	384,00	1203,00	0,54	165,00	50,00	0,80	0,00	0,00	0,00	180	40,30					40,30				
201			309,00	586,00	0,00	195,00	1222,00	0,54	167,00	50,00	0,80	0,00	0,00	0,00	28	36,10					36,10				
202	309,00		586,00	0,00	195,00	1222,00	0,54	167,00	50,00	0,80	0,00	0,00	0,00	180	41,00	41,00									
203		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	0,00	0,00	0,00	2	76,02	59,86									
204		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	0,00	0,00	0,00	7	98,04	77,20									
205		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	0,00	0,00	0,00	14	100,95	79,49									
206		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	0,00	0,00	0,00	28	106,35	83,74									
207		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	0,00	0,00	0,00	56	105,52	83,09									
208		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	0,00	0,00	0,00	90	105,52	83,09									
209		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,10	14,58	0,00	0,00	2	80,17	63,13									
210		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,10	14,58	0,00	0,00	7	100,11	78,83									
211		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,10	14,58	0,00	0,00	14	105,93	83,41									
212		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,10	14,58	0,00	0,00	28	107,18	84,39									
213		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,10	14,58	0,00	0,00	56	107,18	84,39									
214		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,10	14,58	0,00	0,00	90	107,18	84,39									
215		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	17,01	0,00	0,00	2	81,01	63,79									
216		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	17,01	0,00	0,00	7	100,12	78,83									
217		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	17,01	0,00	0,00	14	107,18	84,39									
218		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	17,01	0,00	0,00	28	107,18	84,39									
219		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	17,01	0,00	0,00	56	109,26	86,03									

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolánicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura
220	Ordinary Portland Cement 42.5N	486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	17,01	0,00	0,00	90	109,26	86,03	KHALAF, M. A. ET AL., 2020	Malásia	Cubos - 100x100x100 mm	BS EN 12390-3
221		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	19,44	0,00	0,00	2	80,18	63,13				
222		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	19,44	0,00	0,00	7	104,27	82,10				
223		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	19,44	0,00	0,00	14	109,26	86,03				
224		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	19,44	0,00	0,00	28	112,58	88,65				
225		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	19,44	0,00	0,00	56	113,00	88,98				
226		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,20	19,44	0,00	0,00	90	112,17	88,32				
227		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	21,87	0,00	0,00	2	85,16	67,06				
228		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	21,87	0,00	0,00	7	105,93	83,41				
229		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	21,87	0,00	0,00	14	109,26	86,03				
230		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	21,87	0,00	0,00	28	113,00	88,98				
231		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	21,87	0,00	0,00	56	114,24	89,95				
232		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	21,87	0,00	0,00	90	114,24	89,95				
233		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	24,30	0,00	0,00	2	85,16	67,06				
234		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	24,30	0,00	0,00	7	105,93	83,41				
235		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	24,30	0,00	0,00	14	110,50	87,01				
236		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	24,30	0,00	0,00	28	117,15	92,24				
237		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	24,30	0,00	0,00	56	119,23	93,88				
238		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,30	24,30	0,00	0,00	90	117,98	92,90				
239		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	26,73	0,00	0,00	2	83,50	65,75				
240		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	26,73	0,00	0,00	7	104,27	82,10				
241		486,00	972,00	1458,00	0,00	0	0,23	111,78	50,00	1,40	26,73	0,00	0,00	14	107,18	84,39				
242		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	26,73	0,00	0,00	28	109,26	86,03				
243		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	26,73	0,00	0,00	56	109,26	86,03				
244		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	26,73	0,00	0,00	90	109,26	86,03				
245		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	29,16	0,00	0,00	2	80,59	63,46				
246		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	50,00	1,40	29,16	0,00	0,00	7	102,19	80,46				
247		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	47,74	1,40	29,16	0,00	0,00	14	105,52	83,09				
248		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	47,74	1,40	29,16	0,00	0,00	28	105,93	83,41				
249		486,00	972,00	1458,00	0,00	0,00	0,23	111,78	47,74	1,40	29,16	0,00	0,00	56	105,52	83,09				
250	486,00	972,00	1458,00	0,00	0,00	0,23	111,78	47,74	1,40	29,16	0,00	0,00	90	105,93	83,41					
251	Type I Ordinary Portland Cement	330,00	0,00	880,00	830,00	390,00	0,52	172,00	47,74	1,97	0,00	0,00	0,00	1	27,20	23,45	ABU-EISHAH ET AL., 2012	Emirados Árabes Unidos	Cubos - 150x150x150 mm	ASTM C39
252		330,00	0,00	880,00	830,00	390,00	0,52	172,00	47,74	1,97	0,00	0,00	0,00	3	42,30	36,47				
253		330,00	0,00	880,00	830,00	390,00	0,52	172,00	49,20	1,97	0,00	0,00	0,00	7	54,00	46,55				
254		330,00	0,00	880,00	830,00	390,00	0,52	172,00	49,20	1,97	0,00	0,00	0,00	14	57,50	49,57				
255		330,00	0,00	880,00	830,00	390,00	0,52	172,00	49,20	1,97	0,00	0,00	0,00	21	62,50	53,88				
256		330,00	0,00	880,00	830,00	390,00	0,52	172,00	49,20	1,97	0,00	0,00	0,00	28	64,70	55,78				
257		400,00	0,00	875,00	825,00	390,00	0,38	152,00	49,20	2,13	0,00	0,00	0,00	1	16,70	14,40				
258		400,00	0,00	875,00	825,00	390,00	0,38	152,00	49,20	2,13	0,00	0,00	0,00	3	57,20	49,31				
259		400,00	0,00	875,00	825,00	390,00	0,38	152,00	50,49	2,13	0,00	0,00	0,00	7	68,30	58,88				
260		400,00	0,00	875,00	825,00	390,00	0,38	152,00	50,49	2,13	0,00	0,00	0,00	14	76,00	65,52				
261		400,00	0,00	875,00	825,00	390,00	0,38	152,00	50,49	2,13	0,00	0,00	0,00	21	79,20	68,28				
262		400,00	0,00	875,00	825,00	390,00	0,38	152,00	50,49	2,13	0,00	0,00	0,00	28	80,80	69,66				
263		460,00	0,00	875,00	830,00	390,00	0,29	133,00	50,49	1,52	0,00	0,00	0,00	1	49,70	42,84				
264		460,00	0,00	875,00	830,00	390,00	0,29	133,00	50,49	1,52	0,00	0,00	0,00	3	82,20	70,86				
265		460,00	0,00	875,00	830,00	390,00	0,29	133,00	49,02	1,52	0,00	0,00	0,00	7	86,80	74,83				
266		460,00	0,00	875,00	830,00	390,00	0,29	133,00	49,02	1,52	0,00	0,00	0,00	14	94,30	81,29				
267		460,00	0,00	875,00	830,00	390,00	0,29	133,00	49,02	1,52	0,00	0,00	0,00	21	100,00	86,21				
268		460,00	0,00	875,00	830,00	390,00	0,29	133,00	63,80	1,52	0,00	0,00	0,00	28	102,70	88,53				
269	Pozzolanic Portland Cement Type	370,00	0,00	1247,00	829,00	0,00	0,50	185,00	63,80	0,80	0,00	0,00	0,00	7	44,65	38,49	PAPACHRI STOF OROU ET AL., 2020	Grécia	Cubos - 150x150x150 mm	EN 12390-4
270		370,00	0,00	1247,00	829,00	0,00	0,50	185,00	45,19	0,80	0,00	0,00	0,00	28	54,33	46,84				
271	370,00	0,00	1247,00	829,00	0,00	0,50	185,00	45,19	0,80	0,00	0,00	0,00	90	63,27	54,54	HUANG ET AL., 2016	China	Cubos - 100x100x100 mm	GB/T50080-2002	
272	Typical Portland	54,50	1330,50	785,70	0,00	0,00	2,94	160,00	45,19	3,01	0,00	435,90	54,50	3	53,7					42,28
273	54,50	1330,50	785,70	0,00	0,00	2,94	160,00	45,19	3,01	0,00	435,90	54,50	28	71,40	56,22					
274	330,00	90,50	0,00	512,00	1131,00	0,62	205,00	45,19	0,00	0,00	0,00	0,00	0,00	3	26,64	20,98				

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolânicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura
275	Portland granulated ground blast furnace slag cement	330,00	90,50	0,00	512,00	1131,00	0,62	205,00	45,20	0,00	0,00	0,00	0,00	7	32,16	25,32	QASRAWI ET AL., 2009	Jordânia	Cubos - 100x100x100 mm	ASTM C39
276		330,00	90,50	0,00	512,00	1131,00	0,62	205,00	45,20	0,00	0,00	0,00	0,00	28	37,54	29,56				
277		330,00	90,50	0,00	512,00	1131,00	0,62	205,00	45,20	0,00	0,00	0,00	0,00	90	40,07	31,55				
278		330,00	90,50	0,00	512,00	1131,00	0,62	205,00	45,20	0,00	0,00	0,00	0,00	180	42,69	33,61				
279		330,00	181,00	0,00	422,00	1131,00	0,62	205,00	45,20	0,00	0,00	0,00	0,00	3	25,45	20,04				
280		330,00	181,00	0,00	422,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	7	30,60	24,09				
281		330,00	181,00	0,00	422,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	28	35,37	27,85				
282		330,00	181,00	0,00	422,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	90	37,69	29,68				
283		330,00	181,00	0,00	422,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	180	41,04	32,31				
284		330,00	302,00	0,00	302,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	3	26,19	20,62				
285		330,00	302,00	0,00	302,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	7	31,87	25,09				
286		330,00	302,00	0,00	302,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	28	34,10	26,85				
287		330,00	302,00	0,00	302,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	90	36,27	28,56				
288		330,00	302,00	0,00	302,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	180	38,88	30,61				
289		330,00	604,00	0,00	0,00	1131,00	0,62	205,00	45,23	0,00	0,00	0,00	0,00	3	23,28	18,33				
290		330,00	604,00	0,00	0,00	1131,00	0,62	205,00	49,28	0,00	0,00	0,00	0,00	7	27,01	21,27				
291		330,00	604,00	0,00	0,00	1131,00	0,62	205,00	49,28	0,00	0,00	0,00	0,00	28	29,10	22,91				
292		330,00	604,00	0,00	0,00	1131,00	0,62	205,00	49,28	0,00	0,00	0,00	0,00	90	30,67	24,15				
293		330,00	604,00	0,00	0,00	1131,00	0,62	205,00	49,28	0,00	0,00	0,00	0,00	180	34,63	27,27				
294		427,00	90,00	0,00	510,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	3	26,36	20,76				
295		427,00	90,00	0,00	510,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	7	37,45	29,49				
296		427,00	90,00	0,00	510,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	28	39,6	31,18				
297		427,00	90,00	0,00	510,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	90	43,47	34,23				
298		427,00	90,00	0,00	510,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	180	48,45	38,15				
299		427,00	180,00	0,00	420,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	3	26,02	20,49				
300		427,00	180,00	0,00	420,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	7	35,13	27,66				
301		427,00	180,00	0,00	420,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	28	39,43	31,05				
302		427,00	180,00	0,00	420,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	90	43,38	34,16				
303		427,00	180,00	0,00	420,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	180	47,59	37,47				
304		427,00	300,00	0,00	300,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	3	26,19	20,62				
305		427,00	300,00	0,00	300,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	7	35,30	27,80				
306		427,00	300,00	0,00	300,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	28	38,14	30,03				
307		427,00	300,00	0,00	300,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	90	42,18	33,21				
308	427,00	300,00	0,00	300,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	180	45,19	35,58					
309	427,00	600,00	0,00	0,00	1057,00	0,48	205,00	49,28	0,00	0,00	0,00	0,00	3	20,26	15,95					
310	427,00	600,00	0,00	0,00	1057,00	0,48	205,00	54,02	0,00	0,00	0,00	0,00	7	28,77	22,65					
311	427,00	600,00	0,00	0,00	1057,00	0,48	205,00	54,02	0,00	0,00	0,00	0,00	28	32,98	25,97					
312	427,00	600,00	0,00	0,00	1057,00	0,48	205,00	54,02	0,00	0,00	0,00	0,00	90	36,07	28,40					
313	427,00	600,00	0,00	0,00	1057,00	0,48	205,00	54,02	0,00	0,00	0,00	0,00	180	40,72	32,06					
314	536,00	90,00	0,00	510,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	3	31,56	24,85					
315	536,00	90,00	0,00	510,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	7	41,53	32,70					
316	536,00	90,00	0,00	510,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	28	46,37	36,51					
317	536,00	90,00	0,00	510,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	90	51,01	40,17					
318	536,00	90,00	0,00	510,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	180	56,15	44,21					
319	536,00	180,00	0,00	420,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	3	32,15	25,31					
320	536,00	180,00	0,00	420,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	7	43,51	34,26					
321	536,00	180,00	0,00	420,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	28	47,46	37,37					
322	536,00	180,00	0,00	420,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	90	52,10	41,02					
323	536,00	180,00	0,00	420,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	180	56,94	44,83					
324	536,00	300,00	0,00	300,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	3	28,59	22,51					
325	536,00	300,00	0,00	300,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	7	38,37	30,21					
326	536,00	300,00	0,00	300,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	28	41,33	32,54					
327	536,00	300,00	0,00	300,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	90	45,48	35,81					
328	536,00	300,00	0,00	300,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	180	50,22	39,54					
329	536,00	600,00	0,00	0,00	967,00	0,38	205,00	54,02	0,00	0,00	0,00	0,00	3	25,43	20,02					
330	536,00	600,00	0,00	0,00	967,00	0,38	205,00	59,22	0,00	0,00	0,00	0,00	7	36,49	28,73					
331	536,00	600,00	0,00	0,00	967,00	0,38	205,00	59,22	0,00	0,00	0,00	0,00	28	39,06	30,76					

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolânicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura
332		536,00	600,00	0,00	0,00	967,00	0,38	205,00	59,22	0,00	0,00	0,00	0,00	90	42,12	33,17				
333		536,00	600,00	0,00	0,00	967,00	0,38	205,00	59,22	0,00	0,00	0,00	0,00	180	46,47	36,59				
334	CEM II 42,5/A	470,00	0,00	1050,00	1055,00	0,00	0,31	145,00	58,35	1,33	50,00	0,00	0,00	7	63,09	49,68	BISKRI ET AL., 2017	Argélia	Cubos - 100x100x100 mm	EN 12390-3-2009
335		470,00	0,00	1050,00	1055,00	0,00	0,31	145,00	58,35	1,33	50,00	0,00	0,00	14	72,73	57,27				
336		470,00	0,00	1050,00	1055,00	0,00	0,31	145,00	58,35	1,33	50,00	0,00	0,00	28	84,57	66,59				
337		470,00	0,00	1050,00	1055,00	0,00	0,31	145,00	58,35	1,33	50,00	0,00	0,00	360	87,05	68,54				
338		416,00	0,00	1050,00	1055,00	0,00	0,35	145,00	42,86	1,33	0,00	104,00	0,00	7	53,19	41,88				
339		416,00	0,00	1050,00	1055,00	0,00	0,35	145,00	42,86	1,33	0,00	104,00	0,00	14	64,59	50,86				
340		416,00	0,00	1050,00	1055,00	0,00	0,35	145,00	42,86	1,33	0,00	104,00	0,00	28	70,92	55,84				
341		416,00	0,00	1050,00	1055,00	0,00	0,35	145,00	42,86	1,33	0,00	104,00	0,00	360	74,72	58,83				
342		286,00	0,00	228,80	572,00	915,20	0,5	143	42,86	0,00	0,00	0,00	0,00	7	23,23	20,03				
343		286,00	0,00	228,80	572,00	915,20	0,5	143	42,86	0,00	0,00	0,00	0,00	14	23,82	20,53				
344	286,00	0,00	228,80	572,00	915,20	0,5	143	42,86	0,00	0,00	0,00	0,00	28	25,20	21,72					
345	286,00	0,00	457,60	572,00	686,40	0,50	143	42,86	0,00	0,00	0,00	0,00	7	26,48	22,83					
346	286,00	0,00	457,60	572,00	686,40	0,50	143	42,86	0,00	0,00	0,00	0,00	14	27,57	23,77					
347	286,00	0,00	457,60	572,00	686,40	0,50	143	42,86	0,00	0,00	0,00	0,00	28	29,60	25,52					
348	286,00	0,00	686,40	572,00	457,60	0,50	143	42,86	0,00	0,00	0,00	0,00	7	31,10	26,81					
349	286,00	0,00	686,40	572,00	457,60	0,50	143	42,86	0,00	0,00	0,00	0,00	14	32,19	27,75					
350	286,00	0,00	686,40	572,00	457,60	0,50	143	42,86	0,00	0,00	0,00	0,00	28	32,70	28,19					
351	286,00	0,00	915,20	572,00	228,80	0,50	143	42,86	0,00	0,00	0,00	0,00	7	33,15	28,58					
352	286,00	0,00	915,20	572,00	228,80	0,50	143	42,86	0,00	0,00	0,00	0,00	14	35,34	30,47					
353	286,00	0,00	915,20	572,00	228,80	0,50	143	42,86	0,00	0,00	0,00	0,00	28	37,20	32,07					
354	286,00	0,00	1144,00	572,00	0,00	0,50	143	42,86	0,00	0,00	0,00	0,00	7	34,67	29,89					
355	286,00	0,00	1144,00	572,00	0,00	0,50	143	42,86	0,00	0,00	0,00	0,00	14	36,91	31,82					
356	286,00	0,00	1144,00	572,00	0,00	0,50	143	42,86	0,00	0,00	0,00	0,00	28	39,60	34,14					
357	286,00	0,00	228,80	572,00	915,20	0,55	157,3	42,86	0,00	0,00	0,00	0,00	7	22,70	19,57					
358	286,00	0,00	228,80	572,00	915,20	0,55	157,3	42,86	0,00	0,00	0,00	0,00	14	23,22	20,02					
359	286,00	0,00	228,80	572,00	915,20	0,55	157,3	42,86	0,00	0,00	0,00	0,00	28	25,20	21,72					
360	286,00	0,00	457,60	572,00	686,40	0,55	157,3	42,86	0,00	0,00	0,00	0,00	7	25,23	21,75					
361	286,00	0,00	457,60	572,00	686,40	0,55	157,3	42,86	0,00	0,00	0,00	0,00	14	26,92	23,21					
362	286,00	0,00	457,60	572,00	686,40	0,55	157,3	42,86	0,00	0,00	0,00	0,00	28	28,75	24,78					
363	286,00	0,00	686,40	572,00	457,60	0,55	157,3	42,86	0,00	0,00	0,00	0,00	7	29,90	25,78					
364	286,00	0,00	686,40	572,00	457,60	0,55	157,3	42,86	0,00	0,00	0,00	0,00	14	31,72	27,34					
365	286,00	0,00	686,40	572,00	457,60	0,55	157,3	42,86	0,00	0,00	0,00	0,00	28	32,88	28,34					
366	286,00	0,00	915,20	572,00	228,80	0,55	157,3	42,86	0,00	0,00	0,00	0,00	7	32,60	28,10					
367	286,00	0,00	915,20	572,00	228,80	0,55	157,3	42,86	0,00	0,00	0,00	0,00	14	34,50	29,74					
368	286,00	0,00	915,20	572,00	228,80	0,55	157,3	42,86	0,00	0,00	0,00	0,00	28	36,30	31,29					
369	286,00	0,00	1144,00	572,00	0,00	0,55	157,3	42,86	0,00	0,00	0,00	0,00	7	33,12	28,55					
370	286,00	0,00	1144,00	572,00	0,00	0,55	157,3	42,86	0,00	0,00	0,00	0,00	14	35,42	30,53					
371	286,00	0,00	1144,00	572,00	0,00	0,55	157,3	42,86	0,00	0,00	0,00	0,00	28	38,87	33,51					
372	286,00	0,00	228,80	572,00	915,20	0,60	171,6	42,86	0,00	0,00	0,00	0,00	7	21,67	18,68					
373	286,00	0,00	228,80	572,00	915,20	0,60	171,6	42,86	0,00	0,00	0,00	0,00	14	22,72	19,59					
374	286,00	0,00	228,80	572,00	915,20	0,60	171,6	42,86	0,00	0,00	0,00	0,00	28	24,70	21,29					
375	286,00	0,00	457,60	572,00	686,40	0,60	171,6	42,86	0,00	0,00	0,00	0,00	7	23,70	20,43					
376	286,00	0,00	457,60	572,00	686,40	0,60	171,6	42,86	0,00	0,00	0,00	0,00	14	25,87	22,30					
377	286,00	0,00	457,60	572,00	686,40	0,60	171,6	42,86	0,00	0,00	0,00	0,00	28	27,93	24,08					
378	286,00	0,00	686,40	572,00	457,60	0,60	171,6	42,86	0,00	0,00	0,00	0,00	7	28,90	24,91					
379	286,00	0,00	686,40	572,00	457,60	0,60	171,6	42,86	0,00	0,00	0,00	0,00	14	31,22	26,91					
380	286,00	0,00	686,40	572,00	457,60	0,60	171,6	42,86	0,00	0,00	0,00	0,00	28	32,38	27,91					
381	286,00	0,00	915,20	572,00	228,80	0,60	171,6	42,86	0,00	0,00	0,00	0,00	7	32,10	27,67					
382	286,00	0,00	915,20	572,00	228,80	0,60	171,6	42,86	0,00	0,00	0,00	0,00	14	34,05	29,35					
383	286,00	0,00	915,20	572,00	228,80	0,60	171,6	49,98	0,00	0,00	0,00	0,00	28	35,80	30,86					
384	286,00	0,00	1144,00	572,00	0,00	0,60	171,6	49,98	0,00	0,00	0,00	0,00	7	32,62	28,12					
385	286,00	0,00	1144,00	572,00	0,00	0,60	171,6	49,98	0,00	0,00	0,00	0,00	14	34,92	30,10					
386	286,00	0,00	1144,00	572,00	0,00	0,60	171,6	49,98	0,00	0,00	0,00	0,00	28	37,54	32,36					
387		325,00	0,00	176,40	848,00	997,60	0,50	160	41,97	0,70	0,00	0,00	0,00	7	29,69	25,59				
388		325,00	0,00	176,40	848,00	997,60	0,50	160	41,97	0,70	0,00	0,00	0,00	28	37,60	32,41				

#	Tipo de cimento	Cimento [kg/m³]	Escória de aciaria na fração miúda [kg/m³]	Escória de aciaria na fração graúda [kg/m³]	Agregado miúdo [kg/m³]	Agregado graúdo [kg/m³]	Fator a/c	Consumo de água [L/m³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolânicas [kg/m³]	Adições cimentícias [kg/m³]	Filler [kg/m³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]	Autor, Ano	País	Corpos de Prova	Ensaio de Ruptura
389	Ordinary Portland Cement	325,00	0,00	176,40	848,00	997,60	0,50	160	41,97	0,70	0,00	0,00	0,00	56	43,44	37,45	SAXENA ET AL., 2018	Índia	Cubos - 150x150x150 mm	ASTM C39
390		325,00	0,00	176,40	848,00	997,60	0,50	160	41,97	0,70	0,00	0,00	0,00	90	44,58	38,43				
391		325,00	0,00	293,60	848,00	880,80	0,50	160	41,96	0,70	0,00	0,00	0,00	7	30,21	26,04				
392		325,00	0,00	293,60	848,00	880,80	0,50	160	41,96	0,70	0,00	0,00	0,00	28	39,58	34,12				
393		325,00	0,00	293,60	848,00	880,80	0,50	160	41,96	0,70	0,00	0,00	0,00	56	45,21	38,97				
394		325,00	0,00	293,60	848,00	880,80	0,50	160	41,96	0,70	0,00	0,00	0,00	90	45,83	39,51				
395		325,00	0,00	587,00	848,00	587,00	0,50	160	41,97	0,70	0,00	0,00	0,00	7	33,65	29,01				
396		325,00	0,00	587,00	848,00	587,00	0,50	160	41,97	0,70	0,00	0,00	0,00	28	42,40	36,55				
397		325,00	0,00	587,00	848,00	587,00	0,50	160	41,97	0,70	0,00	0,00	0,00	56	47,19	40,68				
398		325,00	0,00	587,00	848,00	587,00	0,50	160	41,97	0,70	0,00	0,00	0,00	90	48,23	41,58				
399		325,00	0,00	881,00	848,00	293,60	0,50	160	41,95	0,70	0,00	0,00	0,00	7	31,15	26,85				
400		325,00	0,00	881,00	848,00	293,60	0,50	160	41,95	0,70	0,00	0,00	0,00	28	39,17	33,77				
401		325,00	0,00	881,00	848,00	293,60	0,50	160	41,95	0,70	0,00	0,00	0,00	56	43,85	37,80				
402		325,00	0,00	881,00	848,00	293,60	0,50	160	41,95	0,70	0,00	0,00	0,00	90	44,89	38,70				
403		325,00	0,00	1174,00	848,00	0,00	0,50	160	41,97	0,70	0,00	0,00	0,00	7	29,48	25,41				
404		325,00	0,00	1174,00	848,00	0,00	0,50	160	41,97	0,70	0,00	0,00	0,00	28	36,35	31,34				
405		325,00	0,00	1174,00	848,00	0,00	0,50	160	41,97	0,70	0,00	0,00	0,00	56	43,23	37,27				
406		325,00	0,00	1174,00	848,00	0,00	0,50	160	41,97	0,70	0,00	0,00	0,00	90	43,96	37,90				

7.4 Banco de Dados Experimentais de Validação

O banco de dados experimentais usado para a validação foi retirado do trabalho de Costa et al. (2021) e pode ser visto na Tabela 17.

Tabela 17 - Banco de Dados Experimentais. Fonte: adaptado de Costa et al. (2021)

#	Cimento [kg/m ³]	Escória de aciaria na fração miúda [kg/m ³]	Escória de aciaria na fração graúda [kg/m ³]	Agregado miúdo [kg/m ³]	Agregado graúdo [kg/m ³]	Fator a/c	Consumo de água [L/m ³]	Teor de Argamassa (%)	Aditivo (%)	Adições Pozolânicas [kg/m ³]	Adições cimentícias [kg/m ³]	Filler [kg/m ³]	Idade [dias]	Resistência à compressão [Mpa]	Resistência à compressão convertida [Mpa]
1	310	1376,4	1171,86	0	0	0,62	190,65	54,03	0,25	0	0	0	28	23,30	22,19
2	310	1361,16	1161,31	0	0	0,65	201,82	53,98	0,7	0	15,51	0	28	24,67	23,49
3	310	1345,25	1150,26	0	0	0,67	206,99	53,93	0,7	0	23,86	0	28	31,33	29,84
4	310	1330,8	1140,21	0	0	0,69	213,46	53,88	0,3	0	34,29	0	28	23,47	22,35
5	310	1281,23	1105,77	0	0	0,74	229,1	53,69	0,25	0	60	0	28	20,73	19,75
6	450	1224,77	1163,83	0	0	0,44	198	51,30	0,35	0	0	0	28	43,70	41,62
7	450	1180,44	1133,02	0	0	0,46	207,91	51,05	0,48	0	22,52	0	28	38,03	36,22
8	450	1162,65	1120,65	0	0	0,47	213,24	50,94	0,58	0	34,64	0	28	34,50	32,86
9	450	1147,78	1110,32	0	0	0,49	219,9	50,85	0,33	0	49,77	0	28	39,13	37,27
10	450	1090,43	1070,47	0	0	0,53	236,62	50,48	0,2	0	87,1	0	28	30,37	28,92
11	310	936,65	866,31	0	0	0,62	190,65	51,98	0,4	0	0	0	28	14,77	14,06
12	310	930,06	861,74	0	0	0,65	201,82	51,93	0,9	0	15,51	0	28	14,30	13,62
13	310	919,64	854,49	0	0	0,67	206,99	51,86	0,6	0	23,86	0	28	16,20	15,43
14	310	908,85	846,99	0	0	0,69	213,46	51,79	0,35	0	34,29	0	28	13,50	12,86
15	310	874,09	822,85	0	0	0,74	229,4	51,54	0,15	0	60	0	28	12,50	11,90
16	450	818	881,36	0	0	0,44	198	48,17	0,58	0	0	0	28	30,30	28,86
17	450	788,56	860,69	0	0	0,46	207	47,84	0,45	0	22,52	0	28	30,20	28,76
18	450	774,49	850,91	0	0	0,47	213,24	47,68	0,45	0	34,64	0	28	29,90	28,48
19	450	764,4	843,9	0	0	0,49	219,9	47,56	0,2	0	49,77	0	28	24,50	23,33
20	450	723,78	815,67	0	0	0,53	236,32	47,05	0,05	0	87,1	0	28	25,27	24,06

