



**UNIVERSIDADE FEDERAL DE GOIÁS (UFG)/  
UNIVERSIDADE FEDERAL DE CATALÃO (UFCAT) em implantação  
UNIDADE ACADÊMICA INSTITUTO DE FÍSICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS EXATAS E  
TECNOLÓGICAS**

**MONISE RAMOS DA SILVA FERREIRA**

**PREDIÇÃO DA RESISTÊNCIA MECÂNICA DE CONCRETOS COM  
MATERIAIS ALTERNATIVOS ATRAVÉS DE TÉCNICAS DE  
INTELIGÊNCIA ARTIFICIAL**

**CATALÃO**

**2021**



UNIVERSIDADE FEDERAL DE GOIÁS  
UNIDADE ACADÊMICA ESPECIAL DE FÍSICA

## TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

### E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

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

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

#### 1. Identificação do material bibliográfico

Dissertação       Tese

#### 2. Nome completo do autor

Monise Ramos da Silva Ferreira

#### 3. Título do trabalho

Predição da resistência mecânica de concretos com materiais alternativos através de técnicas de inteligência artificial

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

Concorda com a liberação total do documento  SIM       NÃO<sup>1</sup>

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

**a)** consulta ao(à) autor(a) e ao(à) orientador(a);

**b)** novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

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

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



Documento assinado eletronicamente por **André Carlos Silva, Coordenador**, em 17/12/2021, às 17:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Documento assinado eletronicamente por **MONISE RAMOS DA SILVA FERREIRA, Discente**, em 21/12/2021, às 10:59, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do



[Decreto nº 10.543, de 13 de novembro de 2020.](#)



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2584408** e o código CRC **A083A375**.

MONISE RAMOS DA SILVA FERREIRA

**PREDIÇÃO DA RESISTÊNCIA MECÂNICA DE CONCRETOS COM  
MATERIAIS ALTERNATIVOS ATRAVÉS DE TÉCNICAS DE  
INTELIGÊNCIA ARTIFICIAL**

Tese apresentada ao Programa de Pós- Graduação em Ciências Exatas e Tecnológicas da Unidade Acadêmica do Instituto de Física, da Universidade Federal de Goiás (UFG)/ Universidade federal de Catalão (UFCAT) em implantação, como requisito para a obtenção do título de Doutor em Ciências Exatas e Tecnológicas. Área de concentração: Métodos da Ciência e Engenharia de Materiais. Linha de pesquisa: Métodos Teórico-Computacionais em Ciência de Materiais.

Orientador: Prof. Dr. André Carlos Silva

CATALÃO

2021

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

Ferreira, Monise Ramos da Silva  
Predição da resistência mecânica de concretos com materiais alternativos através de técnicas de inteligência artificial / Monise Ramos da Silva Ferreira. - 2021.  
190, xiii f.

Orientador: Prof. Dr. André Carlos Silva.  
Tese (Doutorado) - Universidade Federal de Catalão, Instituto de Física, Catalão, Programa de Pós-Graduação em Ciências Exatas e Tecnológicas, Catalão, 2021.

Apêndice.

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

1. Aprendizado de máquina. 2. Resistência mecânica. 3. Concretos. 4. Estéril de nióbio. 5. Agregado graúdo. I. Silva, Dr. André Carlos, orient. II. Título.

CDU 33



UNIVERSIDADE FEDERAL DE GOIÁS

UNIDADE ACADÊMICA ESPECIAL DE FÍSICA

### ATA DE DEFESA DE TESE

Ata N° 26 da sessão de Defesa de Tese de **nome da aluna Monise Ramos da Silva Ferreira** que confere o título de Doutora em **Ciências Exatas e Tecnológicas**, na área de concentração em **Metodologia da Ciência e Engenharia de Materiais**.

Aos **dezoito dias de novembro de dois mil e um**, a partir das **oito horas**, em sala virtual, realizou-se a sessão pública de Defesa de Tese intitulada **“Predição da resistência mecânica de concretos com materiais alternativos através de técnicas de inteligência artificial”**. Os trabalhos foram instalados pelo Orientador, Professor Doutor **André Carlos Silva (UFCAT)** com a participação dos demais membros da Banca Examinadora: Professor Doutor **Ed Carlo Rosa Paiva (UFCAT)**, membro titular externo; Professor Doutor **Eduardo Noronha de Andrade Freitas (IFG)**, membro titular externo; Professor Doutor **Thiago Jabur Bittar (UFCAT)**, membro titular externo; Professor Doutor **Petrus Henrique Ribeiro dos Anjos (UFCAT)**, membro titular interno. Durante a arguição os membros da banca não sugerem alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Tese tendo sido a candidata **aprovada** pelos seus membros. Proclamados os resultados pelo Professor Doutor **André Carlos Silva**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos **dezoito dias de novembro de dois mil e um**.

TÍTULO SUGERIDO PELA BANCA

#### **Predição da resistência mecânica de concretos com materiais alternativos através de técnicas de inteligência artificial**



Documento assinado eletronicamente por **André Carlos Silva, Coordenador**, em 18/11/2021, às 22:37, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Petrus Henrique Ribeiro Dos Anjos, Vice-Coordenador de Pós-Graduação**, em 19/11/2021, às 11:49, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ed Carlo Rosa Paiva, Professor do Magistério Superior**, em 19/11/2021, às 14:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Thiago Jabur Bittar, Professor do Magistério Superior**, em 25/11/2021, às 13:47, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Documento assinado eletronicamente por **Eduardo Noronha de Andrade Freitas, Usuário Externo**,



em 29/11/2021, às 16:40, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2501265** e o código CRC **BD1EB13F**.

---

**Referência:** Processo nº 23070.060120/2021-71

SEI nº 2501265

## AGRADECIMENTOS

Ao meu orientador, Prof. Dr. André Carlos Silva, por todo apoio e ajuda durante o desenvolvimento deste trabalho.

À CAPES pelo fomento de bolsas, tão importante para nos dedicarmos a pesquisa.

À CMOC *Internacional* pela doação de materiais e recursos financeiros para a produção e caracterização dos concretos produzidos com estéril de nióbio.

Ao LaMPPMin (Laboratório de Modelamento e Pesquisa e Processamento Mineral) da UFCAT, pela colaboração no desenvolvimento, caracterização mecânica, química e mineralógica dos concretos e seus materiais constituintes.

À todos os professores do PPGCET que, direta ou indiretamente, contribuíram com minha formação e realização desta pesquisa.

À todas os amigos e colegas que participaram dessa jornada, com apoio, companheirismo, trocas de ideias e motivação para alcançar este sonho.

À minha família, Dirce, Fátima e Ivan, pelo imenso carinho e incentivo aos estudos desde a infância. Em especial ao meu esposo Eduardo, por todo amor, carinho, paciência e companheirismo.

À Deus, por todas as bênçãos que recebi durante toda minha vida, pela saúde e força na conquista diária de nossos sonhos!

*“É preferível ter a alma  
machucada pelo esforço da  
busca, do que ter a alma sem paz  
por ter desistido de buscar!”*

*(Provérbio Japonês)*

## RESUMO

A escassez dos recursos naturais e os problemas causados pelo acúmulo de resíduos de mineração são os principais responsáveis pelo desenvolvimento de estudos sobre o reaproveitamento desses materiais na composição de concretos. A resistência mecânica é um dos parâmetros de desempenho mais importante e crucial no projeto de estrutura de concreto, entretanto o estudo experimental de concretos demanda alto custo e tempo no processo de confecção e caracterização experimental, além da complexidade intrínseca a heterogeneidade dos componentes dos materiais usados na sua composição. Neste sentido, este trabalho propõe o estudo da predição da resistência à compressão e à tração de concretos produzidos com o resíduo proveniente de rochas encaixantes (estéril) da mineração de nióbio, como substituto do agregado graúdo, através de diferentes técnicas de aprendizagem de máquina e métodos estatísticos (Redes Neurais Artificiais, Máquina de Vetores de Suporte, Árvore de Decisão, Floresta Aleatória, *Gradiente Boosting*, *XGBoosting*, *Ada Boost*, *K-Near Neighbor*, Regressão: Linear Múltipla, Polinomial, LASSO, Ridge, Bayesiana e Mínimos Quadrados Ordinários), de modo a minimizar os custos de produção e desperdício de materiais, causado por um grande número de ensaios de mistura de dosagem. A metodologia consistiu na obtenção dos dados experimentais dos concretos moldados e caracterizados mecanicamente com 0 %, 25 %, 50 %, 75 % e 100 % de substituição de estéril como agregado graúdo, relação água/cimento (a/c) de 0,5 e 0,7, nas idades de cura de 7, 14, 28 e 56 dias. As características mecânicas dos concretos moldados com estéril também foram comparadas com outros tipos de concretos, com dados obtidos da literatura. Os resultados encontrados indicam que as técnicas RNA, Regressão Bayesiana, Regressão Linear Múltipla, Mínimos Quadrados Ordinários, Floresta Aleatória, *Gradiente Boosting* e *XGBoosting* foram eficientes para a predição da resistência mecânica dos concretos produzidos com estéril de nióbio. Os modelos também apresentam os parâmetros de materiais usados na dosagem que têm maior influência no comportamento mecânico desses concretos.

**Palavras-chave:** Aprendizado de máquina. Resistência mecânica. Concretos. Estéril de nióbio. Agregado graúdo.

## ABSTRACT

The scarcity of natural resources and the problems caused by the accumulation of mining residues are mainly responsible for the development of studies on the reuse of these materials in the concrete composition. Mechanical resistance is one of the most important and crucial key performance parameters in concrete structures design. However, the experimental study of these concretes has high cost and is time consuming in the process of making and characterizing specimens, in addition to the intrinsic complexity and heterogeneity of the material components used in the concrete formulation. In this sense, this work proposes the study of the prediction of compressive and tensile strength of concretes produced with the waste from enclosing rocks (also known as sterile) from a niobium mining, as a substitute for coarse aggregate, through different machine learning techniques and other statistical methods (Artificial Neural Networks, Support Vector Machine, Decision Tree, Random Forest, Gradient Boosting, XGBoosting, Ada Boost, K-Near Neighbor, Multiple Linear Regression, Polynomial Regression, LASSO, Ridge, Bayesian, and Ordinary Least Squares). This approach could minimize production costs and material waste, caused by a large number of mixing dosing trials. The methodology consisted of obtaining experimental data of concrete specimens and mechanically characterized with 0, 25, 50, 75 and 100% replacement of coarse aggregate for sterile, water/cement ratio (w/c) of 0.5 and 0.7, in curing periods of 7, 14, 28 and 56 days. The mechanical properties of the concrete specimens with sterile were also compared with other concretes data from the literature. The found results indicate that the machine learning techniques RNA, Multiple Linear Regression, Bayesian, Ordinary Least Squares, Random Forest, Gradient Boosting and XGBoosting were efficient for predicting the mechanical strength of the concrete produced with waste. The models also present the materials parameters used in the concrete formulation that have the greatest influence on the mechanical behavior of these specimens.

**Keywords:** Machine learning. Mechanical resistance. Concrete. Mining sterile of niobium. Coarse aggregate.

## LISTA DE FIGURAS

Figura 1 – Composição do concreto e seus materiais constituintes .....	19
Figura 2 - Estimativa de consumo para o concreto no mundo. (a) Consumo até o ano de 2012; (b) Consumo até o ano de 2030 e (c) Consumo até o ano 2050 .....	20
Figura 3 - Interação dos fatores que influenciam a resistência do concreto.....	24
Figura 4 - Influência do tipo de cimento sobre a resistência do concreto em função da idade. a) Classificação ASTM e b) Classificação ABCP .....	26
Figura 5 – Categorias de ML e aplicações.....	28
Figura 6 – Exemplo de <i>underfitting</i> , <i>overfitting</i> e ajuste ótimo dos modelos de ML .....	33
Figura 7 –Estruturas de um neurônio: a) Neurônio biológico e b) Neurônio artificial .....	34
Figura 8 – Arquitetura de neurônios de uma RNA.....	36
Figura 9 – Treinamento de uma rede MLP <i>feedforward - backpropagation</i> .....	37
Figura 10 – Exemplo de aplicação do SVM destacando os vetores de suporte, o hiperplano ótimo e a margem maximizada .....	40
Figura 11 – Ilustração da estrutura de uma DT .....	42
Figura 12 – Ilustração de métodos <i>ensembles</i> .....	45
Figura 13 – Ilustração da estrutura de uma RF de regressão.....	46
Figura 14 – Modelo do treinamento de um algoritmo <i>Adaboost</i> .....	49
Figura 15 – Exemplo de treinamento do algoritmo GB .....	50
Figura 16 – Exemplo do treinamento de um algoritmo KNN para regressão, variando a quantidade vizinhos.....	54
Figura 17 - Condição de Contorno para Regressão Ridge .....	60
Figura 18 - Condição de Contorno para Regressão LASSO .....	61
Figura 19 - Interpretação geométrica da análise discriminante.....	64
Figura 20 – Ilustração do treinamento do algoritmo de ajuste de hiperparâmetro <i>grid search</i> .....	67
Figura 21 - Fluxograma explicativo da metodologia empregada na pesquisa .....	68
Figura 22 – Caracterização mecânica dos corpos de provas dos concretos produzidos com estéril de nióbio .....	70
Figura 23 – Diagrama de treinamento dos modelos de ML para a resistência dos concretos .	75
Figura 24 – Estrutura das redes neurais artificiais treinadas: a) <i>Data Set 1</i> e b) <i>Data Set 2</i> .....	75
Figura 25 - Resultados médios do ensaio de resistência à $f_{ck}$ . a) Relação a/c de 0,5; b) Relação a/c 0,7 .....	81
Figura 26 - Resultados médios do ensaio de resistência à $f_{ct}$ ; a) Relação a/c de 0,5; b) Relação a/c 0,7 .....	82
Figura 27 - Gráficos de dispersão dos parâmetros do <i>Data Set 1</i> versus a resistência à compressão ( $f_{ck}$ ) dos concretos produzidos .....	85
Figura 28 – Gráficos de dispersão dos parâmetros do <i>Data Set 1</i> versus a resistência à tração ( $f_{ct}$ ) dos concretos produzidos .....	86
Figura 29 – Gráficos de a) Histogramas, b) Boxplots e c) Probabilidade do <i>Data Set 1</i> .....	88
Figura 30 - Correlação de Pearson dos parâmetros do <i>Data Set 1</i> : a) Resistência à compressão ( $f_{ck}$ ) e b) Resistência á tração ( $f_{ct}$ ) .....	92
Figura 31 – Gráfico de intervalos da resistências mecânicas versus as idades do concreto com estéril de nióbio do <i>Data Set 1</i> .....	94

Figura 32 – Gráficos de dispersão dos parâmetros do <i>Data Set 2</i> versus a resistência à compressão ( $f_{ck}$ ) dos concretos compilados da literatura .....	96
Figura 33 – Gráficos: a) Histogramas, b) Boxplots e c) Probabilidade do <i>Data Set 2</i> .....	97
Figura 34 – Correlação de Pearson dos Parâmetros do <i>Data Set 2</i> .....	100
Figura 35 – Agrupamento do <i>Data Set 2</i> nos grupos A, B e C .....	101
Figura 36 – Coeficiente de determinação $R^2$ dos modelos na predição das resistências $f_{ck}$ e $f_{ct}$ .....	103
Figura 37 – Erros RMSE, MAE e MSE dos modelos na predição das resistências $f_{ck}$ e $f_{ct}$ ...	103
Figura 38 – Análise de influência das variáveis nos modelos treinados do <i>Data Set 1</i> . a) Resistência à compressão; b) Resistência à tração. ....	105
Figura 39– Coeficiente de determinação $R^2$ dos modelos na predição da resistência à compressão ( $f_{ck}$ ) do <i>Data Set 2</i> com e sem <i>outlier</i> .....	107
Figura 40 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do <i>Data Set 2</i> .....	107
Figura 41 – Análise de influência das variáveis nos modelos treinados para o <i>Data Set 2</i> ...	109
Figura 42 – Coeficiente de determinação $R^2$ dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do grupo A .....	110
Figura 43 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do grupo A .....	111
Figura 44 – Análise de influência das variáveis nos modelos treinados para o grupo A .....	112
Figura 45 – Coeficiente de determinação $R^2$ dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do grupo B .....	114
Figura 46 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do grupo B .....	114
Figura 47 – Análise de influência das variáveis nos modelos treinados para o grupo B .....	116
Figura 48 – Coeficiente de determinação $R^2$ dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do grupo C .....	117
Figura 49 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem <i>outlier</i> do grupo C .....	118
Figura 50 – Análise de influência das variáveis nos modelos treinados para o grupo C .....	119
Figura 51 – Gráficos dos resíduos para a predição da resistência à compressão dos concretos do <i>Data Set 1</i> .....	121
Figura 52 – Gráficos dos resíduos para a predição da resistência à tração dos concretos do <i>Data Set 1</i> .....	122
Figura 53 – Gráficos dos resíduos para a predição da resistência à compressão dos concretos do <i>Data Set 2</i> .....	123
Figura 54 – Gráficos dos resíduos para a predição da resistência à compressão dos concretos do grupo A .....	124
Figura 55 - Gráficos dos resíduos para a predição da resistência à compressão dos concretos do grupo B .....	125
Figura 56 - Gráficos dos resíduos para a predição da resistência à compressão dos concretos do grupo C .....	126
Figura 57 – Principais variáveis que apresentam maior influência na predição dos modelos de ML .....	128

Figura B. 1 – Gráfico de correlação das variáveis do <i>Data Set 2</i> .....	148
--	-----

## LISTA DE TABELAS

Tabela 1 - Composição dos cimentos <i>Portland</i> normalizados no Brasil.....	21
Tabela 2 – Principais técnicas de ML utilizados na predição de resistência mecânica de concretos .....	29
Tabela 3 – Caracterização dos concretos produzidos com estéril de nióbio e seus materiais constituintes.....	69
Tabela 4 – Autores pesquisados e quantidade de dados que compõe o <i>Data Set 2</i> .....	70
Tabela 5 - Parâmetros selecionados como variáveis de predição dos concretos.....	79
Tabela 6 - Valores dos traços e do consumo de componentes .....	80
Tabela 7 - Abatimento do tronco de cone, umidade relativa do ar e temperatura ambiente....	80
Tabela 8 - Parâmetros selecionados como variáveis de predição dos concretos.....	84
Tabela 9 – ANOVA dos parâmetros do <i>Data Set 1</i> .....	91
Tabela 10 – ANOVA dos parâmetros do <i>Data Set 2</i> .....	99
Tabela 11 – Dados dos conjuntos A, B e C .....	102
Tabela 12 – Resultados da predição dos concretos para o <i>Data Set 1</i> .....	102
Tabela 13 – Resultados da predição dos concretos para o <i>Data Set 2</i> .....	106
Tabela 14 – Resultados da predição dos concretos para o grupo A .....	110
Tabela 15 – Resultados da predição dos concretos para o grupo B .....	113
Tabela 16 – Resultados da predição dos concretos para o grupo C .....	117
Tabela 17 – Melhores modelos de predição da resistência dos concretos .....	120
Tabela A. 1 - Resultados médios do ensaio de resistência à compressão dos concretos produzidos .....	147
Tabela A. 2 - Resultados médios do ensaio de resistência à tração dos concretos produzidos .....	147
Tabela C. 1 – Resultados da predição da resistência $f_{ck}$ do <i>data set 1</i> .....	149
Tabela C. 2 – Resultados da predição da resistência $f_{ct}$ do <i>data set 1</i> .....	149
Tabela C. 3 – Resultados da predição da resistência $f_{ck}$ do <i>data set 2</i> .....	150
Tabela C. 4 – Resultados da predição da resistência $f_{ck}$ do <i>data set 2</i> , dados completos sem <i>outlier</i> .....	150
Tabela C. 5 – Resultados da predição da resistência $f_{ck}$ do grupo A.....	151
Tabela C. 6 – Resultados da predição da resistência $f_{ck}$ do grupo A sem <i>outlier</i> .....	151
Tabela C. 7 – Resultados da predição da resistência $f_{ck}$ do grupo B.....	152
Tabela C. 8 – Resultados da predição da resistência $f_{ck}$ do grupo B sem <i>outlier</i> .....	152
Tabela C. 9 – Resultados da predição da resistência $f_{ck}$ do grupo C.....	153
Tabela C. 10 – Resultados da predição da resistência $f_{ck}$ do grupo C sem <i>outlier</i> .....	153
Tabela D. 1 – Dados do <i>Data Set 1</i> .....	154
Tabela D. 2 – Dados do <i>Data Set 2</i> .....	157

## LISTA DE SÍMBOLOS E SIGLAS

ABCP	Associação Brasileira de Cimento <i>Portland</i>
ABNT	Associação Brasileira de Norma Técnicas
AdaBoost	<i>Adaptive Boosting</i>
ANM	Agência Nacional de Mineração
CMOC	<i>China Molybdenum Co</i>
CP	Cimento <i>Portland</i>
DT	<i>Decision Tree</i>
$f_{ck}$	Resistência à Compressão
$f_{ct}$	Resistência à Tração
IA	Inteligência Artificial
IBRAM	Instituto Brasileiro de Mineração
GB	<i>Gradient Boosting</i>
KNN	<i>K-Near Neighbor</i>
LASSO	<i>Least Absolute Shrinkage and Selection Operator</i>
MAE	<i>Mean Absolut Error</i>
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
MMQ	Método dos Mínimos Quadrados
MMV	Método da Máxima Verossimilhança
MQO	Mínimos Quadrados Ordinários
MSE	<i>Mean Squared Error</i>
$R^2$	Coefficiente de Determinação
Relação a/c	Relação água/cimento
RF	<i>Random Forest</i>
RLM	Regressão Linear Múltipla
RMSE	<i>Root Mean Square Error</i>
RNA	Redes Neurais Artificiais
SVM	<i>Support Vector Machine</i>
<i>XGBoosting</i>	<i>Extreme Gradient Boosting</i>

## SUMÁRIO

<b>RESUMO</b>	<b>iv</b>
<b>ABSTRACT</b>	<b>v</b>
<b>LISTA DE FIGURAS</b>	<b>vi</b>
<b>LISTA DE TABELAS</b>	<b>ix</b>
<b>LISTA DE SÍMBOLOS E SIGLAS</b>	<b>x</b>
<b>1. INTRODUÇÃO</b>	<b>14</b>
<b>1.2 Objetivos da Pesquisa</b>	<b>17</b>
<b>1.3 Estrutura da Pesquisa</b>	<b>18</b>
<b>2. REVISÃO BIBLIOGRÁFICA</b>	<b>19</b>
<b>2.1 Concreto</b>	<b>19</b>
<b>2.1.2 Cimento <i>Portland</i></b>	<b>21</b>
<b>2.1.3 Água</b>	<b>22</b>
<b>2.1.4 Agregados</b>	<b>22</b>
<b>2.1.5 Resistência Mecânica do Concreto</b>	<b>24</b>
<b>2.2 Aprendizado de Máquina (<i>Machine Learning</i> – ML)</b>	<b>27</b>
<b>2.2.1 Técnicas de ML Aplicadas ao Concreto</b>	<b>29</b>
<b>2.3 Técnicas Computacionais e Estatísticas</b>	<b>33</b>
<b>2.3.1 Redes Neurais Artificiais (RNA)</b>	<b>33</b>
<b>2.3.1.2 Arquitetura e Treinamento das RNAs</b>	<b>36</b>
<b>2.3.2 Máquina de Vetores de Suporte (<i>Support Vector Machine</i> – SVM)</b>	<b>39</b>
<b>2.3.3 Árvore de Decisão (<i>Decision Tree</i> - DT)</b>	<b>41</b>
<b>2.3.4 Métodos <i>Ensembles</i></b>	<b>44</b>
<b>2.3.5 Floresta Aleatória (<i>Random Forest</i> - RF)</b>	<b>46</b>
<b>2.3.6 <i>Adaboost</i> (<i>Adaptive Boosting</i>)</b>	<b>47</b>
<b>2.3.7 <i>Gradient Boosting</i> (GB)</b>	<b>49</b>
<b>2.3.8 <i>XGBoosting</i> (XGB)</b>	<b>52</b>
<b>2.3.10 K-Vizinhos Mais Próximos (<i>K-Near Neighbor</i> – KNN)</b>	<b>53</b>
<b>2.3.11 Regressão Linear Múltipla (RLM)</b>	<b>55</b>
<b>2.3.11.1 Regressão Polinomial</b>	<b>57</b>
<b>2.3.11.2 Mínimos Múltiplos Ordinários (MQO)</b>	<b>58</b>
<b>2.3.12 Regressão Ridge</b>	<b>59</b>

2.3.13 Regressão LASSO	60
2.3.14 Regressão Bayesiana	61
2.4 Análise Discriminante	63
2.5 Ajuste de Hiperparâmetros	66
<b>3. MATERIAIS E MÉTODOS</b>	<b>68</b>
3.1 Etapa 1 - Obtenção dos Dados	69
3.2 Etapa 2 – Seleção de Parâmetros, Análise e Pré-Processamento dos Dados	71
3.3 Etapa 3 - Escolha e Processamento dos Modelos	74
3.4 Etapa 4 - Métricas de Avaliação	77
<b>4. RESULTADOS E DISCUSSÃO</b>	<b>79</b>
4.1 Caracterização dos componentes do concreto	79
4.2 Traço e dosagem do concreto.	80
4.3 Concreto no estado fresco	80
4.4 Resistência Mecânica dos Concreto no Estado Endurecido	81
4.5 Análise Gráfica e Estatística dos Dados	83
4.5.1 Análise do <i>Data Set 1</i>	84
4.5.2 Análise do <i>Data Set 2</i>	95
4.6 Agrupamento dos Dados do <i>Data Set 2</i>	101
4.7 Análise da Predição da Resistência dos Concretos	102
4.7.1 Algoritmos de Aprendizagem Aplicados ao <i>Data Set 1</i>	102
4.7.2 Algoritmos de Aprendizagem Aplicados ao <i>Data Set 2</i>	106
4.7.3 Algoritmos de Aprendizagem Aplicados ao Grupo A	110
4.7.4 Algoritmos de Aprendizagem Aplicados ao Grupo B	113
4.7.5 Algoritmos de Aprendizagem Aplicados ao Grupo C	116
4.7.6 Análise dos Resíduos dos Modelos	120
4.8 Análise das Estimativas dos Modelos	127
4.9 Análise das Influência das Variáveis Predictoras	128
<b>5. CONCLUSÃO</b>	<b>130</b>
5.1 Sugestões Para Trabalhos Futuros	132
<b>6. REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>133</b>
<b>APÊNDICES</b>	<b>147</b>
APÊNDICE A – Resultados dos Ensaios de Resistência Mecânica	147
APÊNDICE B – Correlograma do <i>Data Set 2</i>	148

<b>APÊNDICE C - Resultados dos Modelos de Predição da Resistência Mecânica dos Concretos</b>	<b>149</b>
<b>Apêndice D – Dados dos <i>Data Sets</i> 1 e 2 Usados na Predição das Resistências Mecânica dos Concretos</b>	<b>154</b>

## 1. INTRODUÇÃO

A exploração dos recursos minerais é uma prática que tem exercido grande preocupação ambiental nas últimas décadas em todo o mundo (GIUSTOZZI; SAUNIER; ZANNI-MERK, 2018; KOSSOFF, 2014). No Brasil, todos os anos uma enorme quantidade de resíduos sólidos (estéril e rejeitos) são produzidas pelas mineradoras, destinados a aterros e barragens de rejeitos (FERRAZZO; BRAGAGNOLO; KORF, 2020; RODRIGUES; DE BRITO; SARDINHA, 2015). De acordo com a Agência Nacional de Mineração (ANM) e o Instituto Brasileiro de Mineração (IBRAM), após os desastres das barragens de rejeito em Mariana (2015) e Brumadinho (2019), o aproveitamento de rejeitos e estéril é um tema que ganhou grande relevância no país (ANM, 2020; IBRAM, 2019). Com a elevada geração desses resíduos e o pouco reaproveitamento, diversas ações e normativas estão sendo direcionadas para a reutilização e reciclagem dos produtos residuais da mineração de forma mais sustentável (BESSA, 2018; COSTA, 2017; PEDROSO, 2020).

Neste sentido, tanto no Brasil quanto em outros países como China, Índia, Austrália e Canadá têm desenvolvido pesquisas visando a aplicação de resíduos de mineração como matéria-prima para a construção civil, com o intuito de trazer benefícios de ordem econômica, social e ambiental (ASSIS; QUEIROGA; MENDES, 2018; BENARCHID, 2018; CHITHRA, 2016; KORE; VYAS; SYED, 2020; SHARP, 2016). A motivação da aplicação desses resíduos na construção civil, se dá pelo fato desse setor também exercer um grande impacto na exploração mineral, uma vez que necessita de grandes volumes de matérias-primas provenientes da atividade minerária para abastecer as obras de infraestruturas urbanas, construções de rodovias, pontes, ferrovias etc. (MONTEIRO, N., 2017; TRUBBIANELLI, 2021).

Tendo em vista a importância das questões ambientais e do suprimento da demanda, com relação ao consumo de recursos minerais, diversos estudos sobre o uso de resíduos de mineração aplicados como agregados graúdos em concretos, têm sido desenvolvidos com o intuito de atender a demanda dessas duas atividades produtivas e construtivas (ADOM-ASAMOA; AMPOFO; AFRIFA, 2012; KORE; VYAS, 2016; REIS; COLLARES; REIS, 2018; SALIMBAHRAMI; SHAKERI, 2021; SINGH, 2017; ZHU, 2021).

Diante da preocupação em dispor sistematicamente os resíduos e rejeitos, visando minimizar impactos ambientais e melhorar os aspectos de segurança e economia na cidade de

Catalão - GO, empresas mineradoras, como a *China Molybdenum Company Limited* (CMOC), têm buscado estreitar relações com as universidades em diversos projetos de inovação e tecnologia. Entre as parcerias desenvolvidas pela CMOC com a equipe do Laboratório de Modelamento e Pesquisa de Processamento Mineral (LaMPPMin) da UFCAT, está o estudo do reaproveitamento dos resíduos proveniente de rochas encaixantes (estéril) da mineração de nióbio como agregado em concreto, para o consumo de matéria-prima na região. O interesse pelo uso desse material é devido ao grande volume de resíduos gerados diariamente pelas atividades de extração (ou lavra) no decapeamento na mineração e beneficiamento de nióbio (Niobras) e fosfatos (Copebras), que é de aproximadamente de 2 074 t/dia (IN THE MINE, 2019, p. 18).

Entre os materiais mais utilizados na construção civil, o concreto é um dos mais importantes devido à facilidade de moldagem, trabalhabilidade, resistência à água e durabilidade ao longo do tempo (METHA; MONTEIRO, 2014). A resistência mecânica de concretos é uma importante propriedade para se determinar a estabilidade e segurança das estruturas empregadas em construções (NEVILE, 2016). A resistência à compressão é um dos parâmetros mais importantes para validar a qualidade estrutural num projeto, e é geralmente determinado pela realização de vários testes destrutivos em diferentes idades de cura, que demandam gasto de tempo e despesas com matéria-prima e mão de obra (AL-SHAMIRI, 2019; SHARIATI, 2020; ZHOU; CHEN, 2017).

O estudo experimental de concretos produzidos com materiais alternativos, como por exemplo o estéril de nióbio, apresenta muitas complexidades tanto no processo de caracterização dos materiais constituintes, quanto na produção dos corpos de prova, no qual são necessários diversos ensaios experimentais (LOPES, 2018). Considerando a quantidade de corpos de prova necessários para se ter resultados confiáveis na caracterização desses concretos, variando os componentes adotados na sua dosagem (relação a/c, idade, traço), ou ainda, fazendo um estudo comparativo com outros tipos de concretos produzidos com os materiais mais usados no mercado (aditivos, tipos de agregados, tipos de cimentos), em diferentes regiões do país, demandaria muito tempo no processo de produção e ensaios mecânicos, elevado custo com mão de obra e materiais, além da quantidade de resíduos gerados no descarte dos corpos de prova ensaiados (FERRAZZO; BRAGAGNOLO; KORF, 2020; SALGADO, 2018; SILVEIRA, 2015).

Uma abordagem alternativa, para minimizar os ensaios em laboratório, é a utilização de técnicas computacionais baseadas em inteligência artificial (IA), para simular e prever o comportamento mecânico de concretos (FENG, 2020; NUNEZ; NEHDI, 2021; SOUZA; MAGALHÃES; CAMPOS, 2021). As técnicas de IAs oferecem vantagens para lidar com problemas da engenharia civil associados a incertezas e determinação de parâmetros do concreto, quando comparadas às técnicas clássicas de modelagem (SALEHI; BURGUEÑO, 2018; ZHANG, 2021).

Entre as diferentes técnicas de IAs usadas para o estudo de concretos, o aprendizado de máquina tem ao longo da última década adquirido considerável atenção e vem se estabelecendo como uma nova classe de métodos inteligentes para uso nas engenharias (DE CASTRO; LIBORIO; PANDOLFEG, 2011; WANG; GEEM; NAGAI, 2020; YOUNG, 2019).

No estudo de predição da resistência de concretos, as técnicas mais usadas em problemas de regressão são: Redes Neurais Artificiais (RNA) e Máquina de Vetores de Suporte (AHMAD *et al.*, 2021; BEN CHAABENE; FLAH; NEHDI, 2020; DEROUSSEAU; KASPRZYK; SRUBAR, 2018; YASEEN *et al.*, 2018). Porém, métodos *ensembles* e algoritmos de ajuste de hiperparâmetros (*hyperparameter tuning*) estão sendo tendência nos últimos anos como: *Adaptive Boosting (Adaboost)*, *Gradient Boosting (GBoosting)*, *Extreme Gradient Boosting (XGBoosting)*, Árvore de Decisão (DT) e Floresta Aleatória (RF) (ABU YAMAN; ABD ELATY; TAMAN, 2017; FENG, 2020; KALMAN ŠIPOŠ; MILIČEVIĆ; SIDDIQUE, 2017; YASEEN, 2018). Dentre estes estudos, podemos citar alguns trabalhos relevantes sobre o estudo de concretos produzidos com materiais alternativos utilizando IA, que norteiam esta pesquisa.

Zhang, Li e Wang (2020) avaliaram as resistências à compressão e à tração de concretos produzidos com areia manufatura de resíduo de britagem de rochas. Três técnicas de aprendizagem de máquina foram utilizadas para auxiliar na predição da resistência mecânica: (a) Árvore de Decisão, (b) Floresta Aleatória e (c) *Gradient Boosting* e o algoritmo de ajuste de hiperparâmetro *Firefly*.

Wan, Xu e Savija (2021) utilizaram quatro modelos de técnicas de aprendizagem de máquina para prever a resistência à compressão do concreto com base em sua composição de mistura e idade de cura: (a) Regressão Linear, (b) Máquina de Vetor de Suporte (SVM), (c) *Extreme Gradient Boosting (XGBoost)* e (d) Redes Neurais Artificiais (RNA).

Salimbahrami e Shakeri (2021) empregaram duas técnicas de IA: a) Redes Neurais Artificiais (RNAs) e b) Máquina de Vetores de Suporte (SVM), para analisar a resistência mecânica de concretos produzidos com resíduo de construção substituindo os agregados miúdo e graúdos em diferentes porcentagens e reforçados com fibras vegetais.

Neste intuito de melhoria tecnológica, o presente trabalho pretende contribuir com modelos preditivos da resistência mecânica de concretos produzidos com estéril de nióbio, para averiguar com maior rigor sobre os parâmetros que influenciam na sua resistência mecânica, além de propiciar a redução de tempo, custo e geração de resíduos provenientes dos ensaios de caracterização mecânica.

## 1.2 Objetivos da Pesquisa

Avaliar o uso de modelos preditivos baseados em métodos estatísticos e técnicas de aprendizado de máquina, na predição da resistência à compressão ( $f_{ck}$ ) e à tração ( $f_{ct}$ ) de concretos produzidos com material estéril de nióbio como substituto do agregado graúdo.

Para tal, três etapas aplicadas na predição das propriedades mecânicas são desenvolvidas:

- Investigar e aplicar diferentes técnicas de aprendizagem de máquina baseados em métodos de regressão para a predição da resistência mecânica dos concretos produzidos com estéril de nióbio.
- Investigar a influência dos parâmetros (*slump test*, cimento, areia, brita, relação a/c, idade de ruptura) dos materiais utilizados na composição dos concretos produzidos com estéril de nióbio, como dados de entrada na predição da resistência à compressão ( $f_{ck}$ ) e à tração ( $f_{ct}$ ).
- Comparar os modelos e as técnicas computacionais utilizados para predição das resistências mecânicas, avaliando seu potencial de representação com os dados obtidos experimentalmente e banco de dados diversificado compilado da literatura.

### 1.3 Estrutura da Pesquisa

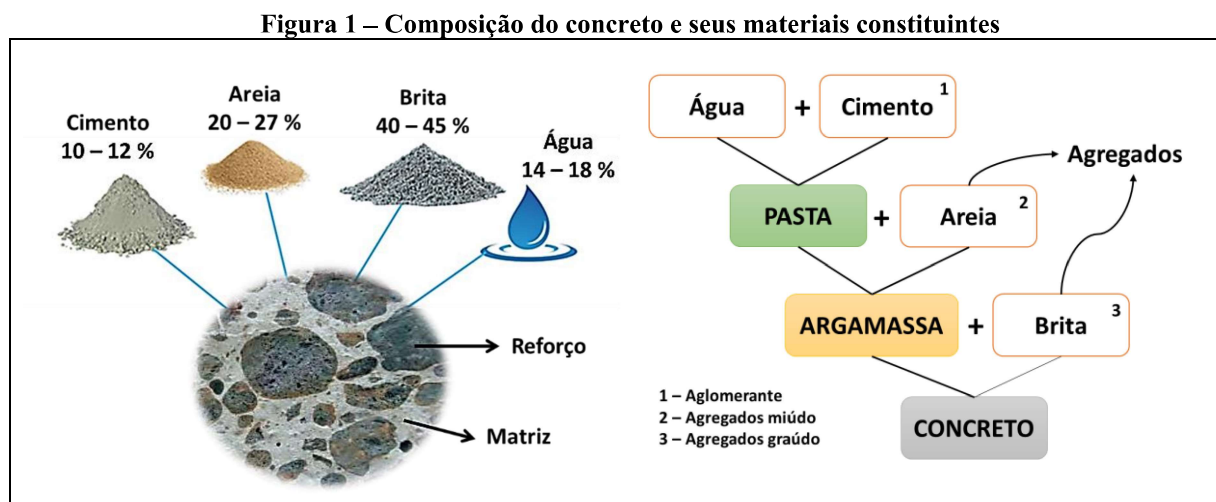
O presente trabalho foi dividido em cinco capítulos. No primeiro foi destacado o contexto que este trabalho se enquadra, a importância do estudo e o problema a ser abordado. O segundo capítulo apresenta a revisão bibliográfica sobre concreto, seus materiais constituintes e os métodos de inteligência computacional usados nessa pesquisa. No terceiro capítulo é descrito o programa experimental usado como referência nas avaliações dos métodos de predição desenvolvidos neste trabalho e a metodologia usada para predição das propriedades mecânicas. No quarto capítulo são apresentados os resultados e discussão do emprego dos métodos aplicados para prever as propriedades mecânicas do concreto. No quinto capítulo são abordadas as considerações finais com conclusões, sugestões para investigações futuras, e as contribuições dessa tese. Em seguida são apresentadas as referências bibliográficas consultadas e Apêndices.

No Apêndice A são apresentados os resultados dos ensaios de resistência mecânica. No Apêndice B é apresentado o gráfico de correlação do *data set 2*. O Apêndice C são apresentados as tabelas com os valores médios das resistências mecânicas dos concretos produzidos com estéril de nióbio e os resultados dos modelos treinados para cada conjunto de dados analisados (*data set 1*, *data set 2*, grupos A, B e C). O Apêndice D apresenta os conjuntos de dados usados no presente estudo.

## 2. REVISÃO BIBLIOGRÁFICA

### 2.1 Concreto

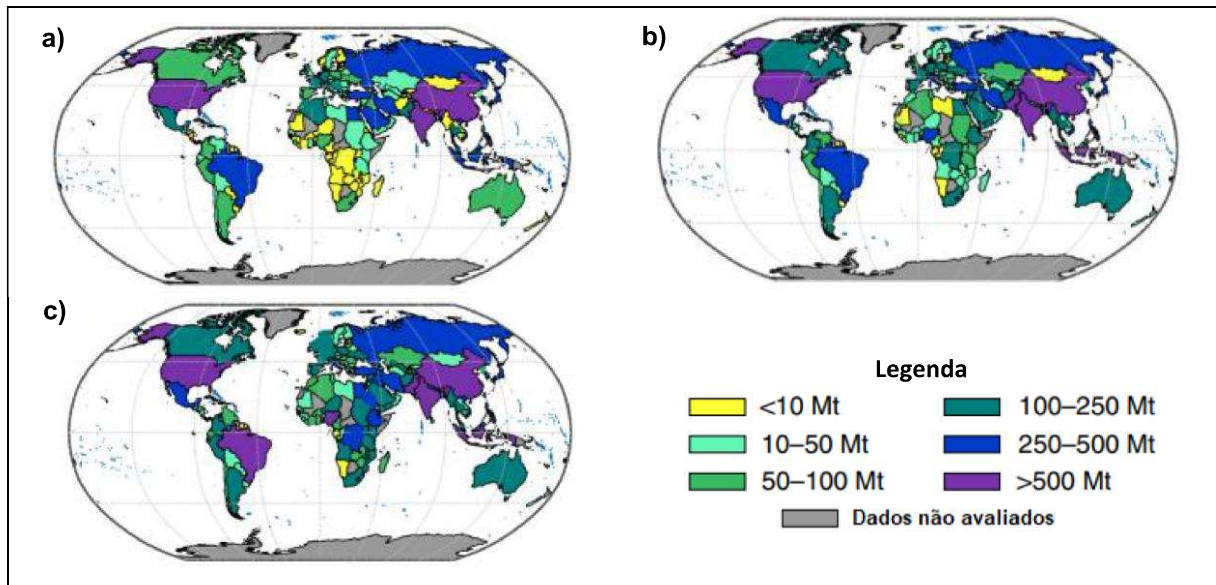
O concreto é classificado como um material composto, resultante da mistura de elementos distintos e insolúveis entre si, da qual se obtém um material com propriedades distintas dos seus constituintes isoladamente. Ele é constituído por duas fases: a matriz composta pela pasta (água e cimento) e reforço composto pelos agregados (areia e brita), conforme ilustrado na Figura 1 (METHA; MONTEIRO, 2008; SILVA JUNIOR, 2010).



Fonte: Autora (2021)

O concreto é o material de construção mais utilizado no mundo, com um consumo anual estimado em 19 bilhões de toneladas, e o segundo em volume consumido pelo homem, ficando atrás somente da água. Estudos estimam que até o ano de 2050 a produção de concreto no Brasil poderá superar 500 Mt/ano (Mt = Mega toneladas) conforme apresentado na Figura 2 (MILLER; HORVATH; MONTEIRO, 2018).

Figura 2 - Estimativa de consumo para o concreto no mundo. (a) Consumo até o ano de 2012; (b) Consumo até o ano de 2030 e (c) Consumo até o ano 2050



Fonte: Miller, Horvath e Monteiro (2018)

Comparado a outros materiais como aço e madeira, o concreto apresenta vantagens competitivas, sendo que ele possui baixo custo de produção, fácil manuseio e boa adaptabilidade a diversos tipos de sistemas estruturais (CARVALHO, 2008).

De acordo com Lorenzi (2009) o concreto é um material altamente complexo, sendo que as relações estrutura-propriedade, geralmente úteis para o entendimento e controle das propriedades dos materiais, não podem ser facilmente aplicáveis e dependem do tratamento dado durante sua mistura e lançamento. A proporção adequada de materiais e a efetividade do processo de cura são críticos para que um concreto possa alcançar o seu desempenho potencial.

Neville (2016) afirma que o comportamento do concreto sofre influência de seus componentes e suas características como forma, textura, tamanho, granulometria, entre outros. Portanto, para se ter uma melhor compreensão da sua durabilidade e resistência mecânica é necessário estudar os materiais constituintes e como se relacionam entre si.

### 2.1.2 Cimento *Portland*

O cimento é um material com propriedades adesivas e coesivas, capaz de unir fragmentos minerais na forma de uma unidade compacta. De modo geral, é uma substância ligante, com capacidade aglomerante, considerado um aglomerante hidráulico, que após reagir com água, sofre transformações químicas-mineralógicas, e juntamente com os agregados, forma um compósito semelhante a uma rocha artificial chamado concreto (NEVILLE, 2016).

Os cimentos *Portland* são cimentos hidráulicos produzidos pela pulverização de clínquer formado essencialmente por silicatos de cálcio hidratados, com adição de sulfatos de cálcio e outros compostos. O cimento *Portland* é fabricado nas etapas seguintes:

- a) Mistura e moagem de materiais calcários e argilosos, nas proporções adequadas (a mistura pode ser seca ou com água);
- b) Tratamento térmico da mistura, em fornos rotativos, até a formação de um material vitrificado, denominado clínquer (1400°C a 1550°C);
- c) Moagem do clínquer com 4 % a 6 % de gesso.

Variando-se a composição do cimento é possível obter diversos tipos, com diferentes características quanto ao tempo de pega, calor de hidratação, resistência mecânica, resistência à sulfatos etc.

A escolha do cimento é baseada no desempenho exigido do concreto quanto à sua resistência mecânica e trabalhabilidade (TANGO, 2005). No Brasil, há vários tipos de cimentos *Portland* sendo produzidos, atendendo a uma diversa gama de aplicações. A Tabela 1 fornece a constituição dos cimentos *Portland* normalizados no Brasil.

**Tabela 1 - Composição dos cimentos *Portland* normalizados no Brasil**

Tipos de cimento <i>Portland</i>	Sigla	Constituição				Normas ABNT
		Clínquer + Gesso	Escória	Pozolana	Material Carbonático	
Comum	CP I	100%		0%		
	CP I - S	95 – 99%		1 – 5%		
Composto	CP II – E	56 – 94%	6 – 34%	0%	0 – 10%	NBR 5732
	CP II – Z	76 – 94%	0%	6 – 14%	0 – 10%	
	CP II – F	90 – 94%	0%	0%	6 – 10%	
Alto-forno	CP III	25 – 65%	35 – 70%	0%	0 – 5%	NBR 11578

Pozolânico	CP IV	45 – 85%	0%	15 – 50%	0 – 5%	NBR 5736
Alta Resistência Inicial	CP V ARI	95 – 100%	0%	0%		NBR 5733
Resistência aos Sulfatos	RS	Idêntica aos cinco anteriores, do qual é derivado				NBR 5737
Destinados à Cimentação de Poços Petrolíferos	CPP classe G	100%		0%		NBR 9831

Fonte: Adaptado de Neville (2016)

### 2.1.3 Água

A água adicionada ao concreto apresenta duas funções importantes e divide-se em: água de hidratação, que reage com o cimento e contribui para o aumento da resistência, e a água de amassamento que confere plasticidade ao concreto. Essa última quando não dimensionada na quantidade certa, pode contribuir negativamente na resistência, portanto, deve-se preferencialmente reduzir dentro dos limites de trabalhabilidade a quantidade de água. A quantidade de água relacionada à quantidade de cimento utilizado na mistura, denomina-se relação água/cimento (a/c) (NEVILLE, 2016).

### 2.1.4 Agregados

Agregado é definido como material granular, sem forma ou volume definidos, de dimensões e propriedades adequadas para fabricação de concretos e argamassas. Os agregados devem ser formados por partículas resistentes e sem a presença de materiais deletérios como: argila, mica, silte, sais, matéria orgânica etc. (ANDOLFATO, 2002).

Segundo Neville (2016) os agregados têm grande importância nos concretos, tanto do ponto de vista econômico como técnico, uma vez que constituem  $\frac{3}{4}$  do seu volume, possuem resistência e durabilidade superior à pasta de cimento. Além disso, algumas características importantes devem ser avaliadas para qualificar os agregados para uso na produção do concreto como: composição granulométrica, forma e textura superficial, resistência mecânica, absorção e umidade superficial.

Os agregados podem ser classificados quanto à dimensão dos grãos, segundo a ABNT NBR 7211:2005, em:

- Agregado graúdo: é o agregado cujos grãos passam pela peneira com abertura de malha 152 mm e ficam retidos na peneira com abertura de malha de 4,75 mm, em ensaio realizado de acordo com a ABNT NBR NM 248:2003, com peneiras padronizadas pela norma ABNT NBR ISO 3310-1:2010;
- Agregado miúdo: é aquele cujos grãos passam pela peneira com abertura de malha de 4,75 mm e ficam retidos na peneira com abertura de malha de 0,075 mm em ensaio realizado de acordo com a ABNT NBR NM 248:2003 com peneiras de acordo com ABNT NBR ISO 3310-1:2010.

Os agregados também podem ser classificados quanto sua origem como (NETO; OLIVEIRA; RAMOS, 2011):

- Naturais: aqueles que são encontrados na natureza já preparados para uso sem beneficiamento que não seja a lavagem, ex.: areia de rio, pedregulho, areia de cava, entre outros;
- Britados: quando são submetidos a processo de cominuição, geralmente por britagem;
- Artificiais: oriundos de processos industriais, ex. argila expandida e peletizada;
- e
- Reciclados: que podem ser resíduos industriais granulares ou entulho de construção ou demolição, ex.: escória de alto-forno, estéril de mineração etc.

De acordo com Andriolo e Sgarboza (1993), o agregado pode influenciar de formas diferentes nas propriedades do concreto, tanto em seu estado fresco como endurecido:

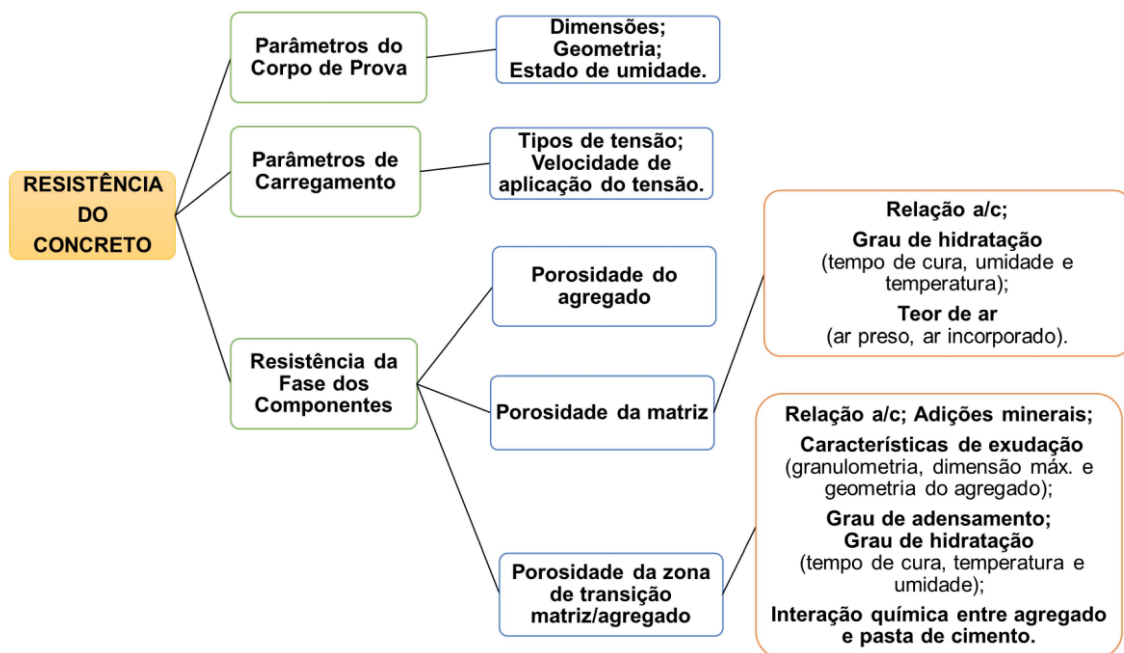
- A superfície do agregado influencia na trabalhabilidade do concreto no estado plástico e na aderência do concreto endurecido;
- A graduação das partículas do agregado influencia na trabalhabilidade, compacidade e economia do concreto;
- A mineralogia das partículas do agregado influencia na resistência, deformação, durabilidade, estabilidade térmica do concreto e na massa específica influencia na estabilidade volumétrica dada a secagem do concreto.

### 2.1.5 Resistência Mecânica do Concreto

A resistência mecânica é uma propriedade muito importante do concreto e traduz-se na resistência à compressão, à tração, à flexão e ao cisalhamento. É a resistência que permite que elementos estruturais de concreto suportem altas cargas em serviço sem entrar em colapso (METHA; MONTEIRO, 2008).

De acordo com Mehta e Monteiro (2008), vários fatores podem influenciar de forma significativa a resistência mecânica do concreto no estado endurecido. Um quadro esquemático destes fatores é apresentado na Figura 3.

Figura 3 - Interação dos fatores que influenciam a resistência do concreto



Fonte: Adaptado de Mehta e Monteiro (2008)

Ambrozewicz (2012) destaca ainda como principais fatores influentes a relação a/c, a idade do concreto, a forma e granulometria dos agregados, o tipo de cimento utilizado para a formulação do concreto e as condições de cura.

A variação da relação a/c influencia diretamente na resistência mecânica do concreto no estado endurecido. O aumento pode significar maior quantidade de água na mistura, causando diminuição da resistência mecânica. Sua redução, ao contrário, pode permitir a obtenção de

concretos com maior resistência mecânica. Entretanto, a trabalhabilidade da mistura fica prejudicada. Daí, a importância de uma relação a/c que permita que propriedades como a trabalhabilidade e a resistência mecânica sejam atendidas de forma satisfatória (REMACHANDRAN; BEAUDOIN, 2000).

O processo de endurecimento de concretos à base de cimento *Portland* é muito longo e pode perdurar por anos. O aumento da idade permite que ele ganhe resistência, isto é, aumente sua capacidade de resistência mecânica. Com 28 dias, o concreto adquire de 75 % a 90 % de sua resistência final e é com base nesse valor, obtido por meio de ensaios experimentais, que as estruturas de concreto são projetadas (MEHTA; MONTEIRO, 2008).


A cura é um procedimento utilizado para favorecer a hidratação do cimento pelo controle da temperatura e movimento de água para dentro e para fora do concreto. Deste modo, influencia diretamente na umidade e na temperatura do concreto nas primeiras idades, garantindo que as propriedades de resistência mecânica do concreto sejam atingidas (SHETTY, 2005).

As propriedades do agregado gráudo como: o tamanho, a forma, a textura da superfície, a granulometria e a mineralogia influenciam na resistência do concreto. De acordo com Alhadas (2008), uma mudança no diâmetro máximo de um agregado gráudo com distribuição granulométrica bem graduada e de uma dada mineralogia pode ter dois efeitos opostos sobre a resistência do concreto. Para o mesmo teor de cimento e mesma consistência do concreto, as misturas contendo partículas de agregados grandes requerem menos água de amassamento do que aquelas que contêm agregados menores. Mas, ao contrário, agregados grandes tendem a formar zonas de transição mais fracas contendo mais microfissuras. O efeito resultante varia com o fator a/c do concreto e a tensão aplicada.

De acordo com Neville (2016) os tipos de cimento também são importantes para o ganho de resistência mecânica do concreto. A velocidade de hidratação e o crescimento da resistência dependem da finura das partículas do cimento e sua distribuição granulométrica. Tanto a relação a/c quanto o grau de hidratação do cimento tem efeito direto na porosidade da pasta de cimento endurecida. Assim, sob condições padrões de cura e uma dada relação a/c, os tipos de cimentos *Portland* mais finos, hidratam-se mais rapidamente nas primeiras idades, apresentando baixa porosidade e uma resistência mais alta. Por outro lado, cimentos *Portland* que têm a taxa de hidratação de cimentos mais lentas até os 28 dias, apresentam uma resistência mais baixa nas primeiras idades, porém a partir de 90 dias apresentam maior resistência ou similar. Um

comparativo sobre esse ganho de resistência em relação à maturação dos concretos pode ser observado na Figura 4 e no Quadro 1. Portanto, a influência da composição do cimento sobre a porosidade da matriz e a resistência do concreto ficam limitadas a baixas idades.

**Figura 4 - Influência do tipo de cimento sobre a resistência do concreto em função da idade. a) Classificação ASTM e b) Classificação ABCP**



Fonte: Neville (2016)

**Quadro 1 - Influência do tipo de cimento nas propriedades de pastas, argamassas e concretos**

Influência	Tipo de Cimento					
	Comum e Composto	Alto-Forno	Pozolânico	Alta Resistência Inicial	Resistente aos Sulfatos	Branco Estrutural
Resistência à compressão	Padrão	Menor nos primeiros dias e maior no final da cura	Menor nos primeiros dias e maior no final da cura	Muito maior nos primeiros dias	Padrão	Padrão
Calor gerado na reação do cimento com a água	Padrão	Menor	Menor	Maior	Padrão	Maior
Impermeabilidade	Padrão	Maior	Maior	Padrão	Padrão	Padrão
Resistência aos agentes agressivos (água do mar e esgotos)	Padrão	Maior	Maior	Menor	Maior	Menor
Durabilidade	Padrão	Maior	Maior	Padrão	Maior	Padrão

Fonte: Adaptado da ABCP (2002)

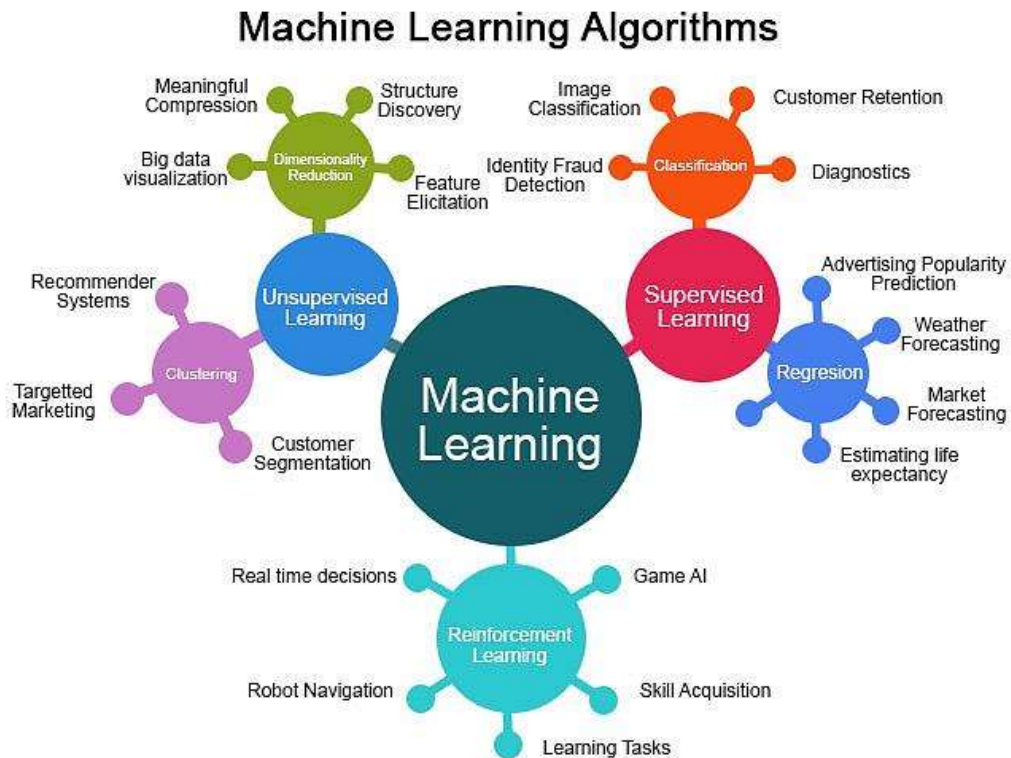
## 2.2 Aprendizado de Máquina (*Machine Learning* – ML)

Aprendizado de máquina ou do inglês *Machine Learning*, é uma tecnologia onde os computadores têm a capacidade de aprender automaticamente com um conjunto de dados e por meio de associações de diferentes categorias (imagens, caracteres e números) consegue identificar padrões (CHOLLET, 2018). O ML juntamente com as tecnologias de *Big Data* e computação de alto desempenho, foram implementados com o objetivo de desenvolver novas possibilidades para desvendar, quantificar e entender uma grande quantidade de dados estruturados e não estruturados, advindos da era da tecnologia moderna (LIAKOS *et al.*, 2018).

As metodologias que envolvem a ML buscam a aquisição de conhecimento com o objetivo de aprender com a experiência para a execução de uma tarefa, e para isso, compartilha de um campo interdisciplinar com a estatística, teoria da informação, teoria de jogos e otimização (SHALEV-SHWARTZ; BEN-DAVID, 2013). O treinamento de um sistema ML é feito com a inserção de um conjunto de dados de entrada, onde através de exemplos relevantes para executar uma tarefa, encontra-se uma estrutura estatística, que permite ao sistema criar as próprias regras para automatizá-lo. Assim, essas regras são os dados de saída, que podem ser aplicadas a novos dados para produzir respostas (LAKE *et al.*, 2017).

Para capturar e utilizar o conhecimento adquirido, a aprendizagem de máquina utiliza de tarefas que são classificadas em três categorias principais, definidas como: aprendizagem supervisionada, não supervisionada e por reforço (Figura 5). Essas categorias são utilizadas de acordo com o tipo de resolução que serão aplicados nos problemas (ZHANG; LI; WANG, 2020).

Figura 5 – Categorias de ML e aplicações



Fonte: Educa (2021)

No aprendizado não supervisionado o objetivo é separar o conjunto de dados usando métodos de aproximação, através de padrões ocultos ou estruturas inerentes aos dados de entrada. Nessa técnica, os dados não são rotulados e não há um modelo explícito de treinamento. Os tipos de treinamento não supervisionado são os métodos de agrupamento ou associação, que busca similaridade entre os dados e, após identificá-los, segrega os itens entre grupos específicos (clusters). Ou ainda, os métodos de redução de dimensão, que diminui o número de variáveis aleatórias a fim de obter um conjunto de variáveis principais.

No aprendizado por reforço, nenhuma informação é fornecida em relação ao sinal de categoria desejada ou objetivos explícitos. Os algoritmos de reforço são forçados a aprender os objetivos ideais, por meio de tentativa e erro. Para maximizar o desempenho do modelo, a aprendizagem por reforço permite que um agente determine o comportamento ideal dentro de um contexto específico. Os agentes recebem uma recompensa numérica como um sinal de reforço, que codifica o sucesso do resultado de uma ação. O objetivo do agente é, então, aprender a selecionar ações que maximizem a recompensa acumulada ao longo do tempo.

### 2.2.1 Técnicas de ML Aplicadas ao Concreto

Nos últimos anos, o desenvolvimento de computadores cada vez mais poderosos têm contribuído para o aumento do uso de técnicas de modelagem computacional usando ML em áreas muito diferentes de engenharia e pesquisa. Essas ferramentas conseguem melhorar substancialmente qualquer modelo anterior proposto.

Na área da engenharia civil, tem havido muitas aplicações de técnicas de ML, como monitoramento da vida útil de estruturas, previsão de diferentes propriedades mecânicas do concreto, projeto de otimização de elementos estruturais, dosagem de concretos com materiais alternativos etc. (CHOU *et al.*, 2014; CIHAN, 2019).

Técnicas de ML baseadas em dados também têm apresentado resultados promissores na previsão das propriedades mecânicas de concretos produzidos com materiais alternativos como: resíduos industriais de mineração, de construção e demolição (CHEN; ZHAO; BIE, 2020; DESHPANDE; LONDHE; KULKARNI, 2014; KHADEMI *et al.*, 2016; MA *et al.*, 2021; MAGHFOURI *et al.*, 2020; OMRAN; CHEN; JIN, 2016; RAJESHWARI; MANDAL, 2019; SALIMBAHRAMI; SHAKERI, 2021). No entanto, ainda é limitada a quantidade de pesquisas existentes de ML no estudo de concretos com resíduos de mineração.

Para nortear esta pesquisa sobre os principais métodos já utilizados na predição da resistência mecânica de concretos, fez-se uma busca dos periódicos revisados em pares mais relevantes sobre o uso de ML aplicado à resistência de concretos. Ao todo foram selecionados 52 trabalhos que abordam as principais técnicas de ML, metodologias empregadas e resultados alcançados, que serviram de referência nesta pesquisa, conforme apresentado na Tabela 2.

**Tabela 2 – Principais técnicas de ML utilizados na predição de resistência mecânica de concretos**

Tipos de concreto	Ensaio	Métodos de ML	Autores
CC	Compressão	DT, RNA e GRADIENT BOOSTING	(AHMAD <i>et al.</i> , 2021)
CAR	Compressão	RNA	(AL-SHAMIRI <i>et al.</i> , 2019)
Fibra de aço	Compressão, Tração	REGRESSÃO NÃO LINEAR, SVM, RNA e DT	(BEHNOOD; VERIAN; MODIRI GHAREHVERAN, 2015)

CC	Compressão	SVM, RNA e EA	(BEN CHAABENE; FLAH; NEHDI, 2020)
CC	Compressão	GA	(CASTELLI; VANNESCHI; SILVA, 2013)
CC	Compressão	RNA, XGBOOSTING e KNN	(AHMADI- NEDUSHAN, 2012)
CC	Compressão	SVM	(CHEN <i>et al.</i> , 2009)
CAR	Compressão	RNA, SVM, DT e REGRESSÃO LINEAR	(CHOU <i>et al.</i> , 2014)
CC	Compressão <i>Slump</i>	FUZZY LOGIC	(CIHAN, 2019)
CC	Compressão	XGBOOSTING e GA-RNA	(CUI <i>et al.</i> , 2021)
CC	Compressão	RF, DT e GRADIENT BOOSTING	(DAHIYA, N.; SAINI, B.; CHALAK, 2021)
CC	Compressão	RNA, KNN, DT e SVM	(DEROUSSEAU; KASPRZYK; SRUBAR, 2018)
RCD	Compressão	RNA, POLINOMIAL e DT	(DESHPANDE; LONDHE; KULKARNI, 2014)
CAR	Compressão	RNA e ADABOOST	(ERDAL, 2013)
CC	Compressão	RNA e SVM	(FENG <i>et al.</i> , 2020)
RCD	Compressão	SVM e DT	(GHOLAMPOUR <i>et al.</i> , 2020)
CAR	Compressão	RF	(HAN <i>et al.</i> , 2019)
CC	Compressão, <i>Slump</i>	SVM	(HOANG; PHAM, 2016)
Fibra de aço	Compressão	SVM	(HUANG <i>et al.</i> , 2020)
Borracha	Compressão	RNA, SVM, ANFIS e GA	(JALAL <i>et al.</i> , 2020)
Cinzas	Compressão	SVM,	(LATIF, 2021)
RM	Compressão	SVM, ADABOOST e DT	(MA <i>et al.</i> , 2021)
CC	Compressão	RNA	(NEHDI; EL CHABIB; EL NAGGAR, 2001)
CC	Compressão	RNA, SVM e XGBOOSTING	(NGUYEN-SY <i>et al.</i> , 2020)
CAR	Compressão, Tração	RNA, SVM, GRADIENTBOOSTING e XGBOOSTING	(NGUYEN <i>et al.</i> , 2021a)
RCD	Compressão	ADABOOST	(NUNEZ; MARANI; NEHDI, 2020)
RM	Compressão	RNA, SVM, ADABOOST, DT e ANFIS	(OMRAN; CHEN; JIN, 2016)
RCD	Compressão, Tração e Flexão	ANFIS	(REZAIEE-PAJAND <i>et al.</i> , 2021)
CC	Compressão	RNA e SVM	(PARK; YOON; OH, 2019)
CAR	Compressão	SVM	(PHAM; HOANG; NGUYEN, 2016)
CC	Compressão	GRADIENT BOOSTING	(RATHAKRISHNAN; BEDDU; AHMED, 2021)

CC	Compressão, SLUMP	SVM	(SAHA; DEBNATH; THOMAS, 2020)
Cinzas	Compressão	RNA e DT	(SONG <i>et al.</i> , 2021)
CC	Compressão	SVM	(TINOCO; GOMES CORREIA; CORTEZ, 2014)
CC	Compressão	RNA	(WAN, Z.; XU, Y.; SAVIJA, 2021)
CC	Compressão, Corrosão	SVM	(WANG; GEEM; NAGAI, 2020)
CC	Compressão	SVM	(YU <i>et al.</i> , 2018)
Leve	Compressão	NAIVE BAYES	(YASEEN <i>et al.</i> , 2018)
CAR	Compressão	RNA	(YEH, 1998)
CC	Compressão	RNA, DT e SVM	(YOUNG <i>et al.</i> , 2019)
RCD	Compressão	SVM	(YU <i>et al.</i> , 2018)
RM	Compressão	SVM, RT e ADABOOST	(ZHANG; LI; WANG, 2020)
CC	Compressão	RNA	(ZIOLKOWSKI; NIEDOSTATKIEWICZ, 2019)
CC	Compressão	DT, RNA e RF	(CHOPRA <i>et al.</i> , 2018)
CAR	Compressão, Dosagem	RNA	(KE; DUAN, 2021)
Cinzas	Compressão	KNN, RIDGE, LASSO, ADABOOST, DT e RF	(JHA <i>et al.</i> , 2020)
RCD	Compressão	KNN, ADABOOST, RF, SVM e RNA	(HAN <i>et al.</i> , 2020)
Borracha	Compressão	RNA, XGBOOSTING, RF e DT	(HADZIMA-NYARKO <i>et al.</i> , 2020)
CAR	Compressão	RNA, DT e RF	(FAROOQ <i>et al.</i> , 2020)
RCD	Compressão	XGBOOSTING, RNA, SVM e ANFIS	(KE; DUAN, 2021)
RCD	Compressão, Dosagem	RF	(XU <i>et al.</i> , 2021)
CC	Compressão	RF, SVM, KNN, DT e ADABOOST	(KOYA <i>et al.</i> , 2021)

**CC – concreto comum; CAR – concreto de alta resistência; RCD – resíduo de construção e demolição; RM – resíduo de mineração; RF – floresta aleatória; DT – árvore de decisão; ANFIS – adaptive-network-based fuzzy inference system; GA – algoritmo genético; EA – algoritmos evolutivos. Fonte: Autora (2021)**

Os trabalhos selecionados como referência trazem diversas orientações de como usar com eficácia as técnicas de ML na previsão da resistência de concretos. De acordo com Hadzima-Nyarko *et al.* (2020) os parâmetros usados nos dados de entrada, os modelos selecionados e os hiperparâmetros são fatores-chave para atingir a precisão desejável. A maioria desses estudos abordam sobre o uso das proporções de mistura do concreto, junto com a idade de teste como parâmetros de entrada. As principais informações comumente utilizadas são: mistura de água, cimento, agregado miúdo e agregado graúdo (CHENG; FIRDAUSI;


PRAYOGO, 2014; CHOPRA *et al.*, 2018; DESHPANDE; LONDHE; KULKARNI, 2014; DUAN *et al.*, 2018).

Na entrada dos dados, os parâmetros são geralmente escalados por meio de funções com um domínio entre  $[0,1]$  ou  $[-1;1]$ , podendo ser transformados, usando técnicas de normalização como os métodos de *Box-Cox* ou *Z-scores*. As métricas de desempenho mais usada para medir a acurácia dos modelos são: o coeficiente de determinação  $R^2$ , os erros médio quadrático (RMSE e MSE) e erro médio absoluto (MAE) (MA *et al.*, 2021; NADERPOUR *et al.*, 2019; NUNEZ; NEHDI, 2021; PHAM; HOANG; NGUYEN, 2016; WAN, Z.; XU, Y.; SAVIJA, 2021; YAN; SHI, 2010; YASEEN *et al.*, 2018).

Esses trabalhos também tratam sobre a importância do uso de ferramentas estatísticas e método de regressão, para estimar a relação entre os parâmetros a partir dos dados disponíveis. De acordo com KOYA *et al.* (2021), os componentes principais dos métodos de regressão para realizar uma boa análise estatística são: um banco de dados; um modelo matemático; uma medida de adequação para avaliar a precisão preditiva do modelo e uma estratégia de ajuste do modelo matemático (MOHAMMED *et al.*, 2021).

Além disso, é ressaltado sobre a importância de ajustar adequadamente o modelo matemático, encontrando um equilíbrio entre o sobreajuste do modelo (*overfitting*) e o subajuste do modelo (*underfitting*). No caso de *overfitting* do modelo matemático, ocorrerá um ajuste excessivo da amostra específica, porém tal modelo não é uma boa representação da realidade, se mostrando ineficaz para prever novos resultados. Já no caso de *underfitting*, o desempenho do modelo apresenta um desempenho ruim no próprio treinamento, levando a falta de ajuste e baixo poder de generalização dos dados analisados. A Figura 6, apresenta um exemplo de *overfitting*, *underfitting* e ajuste ótimo de um modelo.

Figura 6 – Exemplo de *underfitting*, *overfitting* e ajuste ótimo dos modelos de ML



Fonte: Adaptado de Martini (2019)

## 2.3 Técnicas Computacionais e Estatísticas

A seguir são apresentadas as técnicas de ML utilizadas neste trabalho, aplicados a problemas de regressão para a predição da resistência mecânica do concreto.


### 2.3.1 Redes Neurais Artificiais (RNA)

As redes neurais artificiais é uma das técnicas de ML mais utilizadas no estudo de resistência de concretos. O poder de precisão e generalização desta técnica aplicada a problemas não lineares, fez com que uma ampla gama de estudos tenham sido desenvolvidas ao longo da última década (ACUÑA *et al.*, 2014; BKA *et al.*, 2021; CORREIA, 2016; DUAN; KOU; POON, 2013; HADZIMA-NYARKO *et al.*, 2020; MAYORCA, 2020; NEELAKANTA; DE GROFF, 2018; OLIVEIRA FILHO, 2019; TOGHROLI *et al.*, 2018; ZIOLKOWSKI; NIEDOSTATKIEWICZ, 2019).

De acordo com Lorenzi *et al.* (2017), redes neurais artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. As RNAs são formadas por neurônios que têm seu funcionamento baseado no neurônio biológico do sistema nervoso (ABU YAMAN; ABD ELATY; TAMAN, 2017; FERREIRA, 2016). O neurônio artificial é uma estrutura lógico-matemática que representa uma região, onde as informações inseridas nos sinais de entradas ( $x_j$ ) são processadas e as conexões entre elas, são responsáveis pelo armazenamento das informações.

A Figura 7 apresenta um esquema do neurônio biológico (4a) e um neurônio artificial (4b) baseado no modelo de McCulloch e Pitts de 1943. O modelo inclui um sinal adicional chamado de bias ( $b_k$ ), que favorece ou limita a possibilidade de ativação do neurônio. O processo sináptico do neurônio matemático é representado pelos pesos ( $w_{kj}$ ) que amplificam cada um dos sinais recebidos, a função de ativação ( $\varphi$ ) modela a forma como o neurônio responde ao nível de excitação, delimitando e definindo a saída da rede neural (FURTADO, 2019).

Figura 7 –Estruturas de um neurônio: a) Neurônio biológico e b) Neurônio artificial



Fonte: Adaptado de a) Furtado (2019) e b) Haykin (2009).

De modo geral, o neurônio artificial tem seu funcionamento associado ao neurônio biológico da seguinte forma (LORENZI, 2009; PESTANA, 2017):

- Sinais de entrada  $(x_1, x_2, \dots, x_m)$ : equivalem aos impulsos elétricos externos captados pelos dendritos, valores utilizados para o treinamento da RNA;
- Pesos sinápticos  $(w_{k1}, w_{k2}, \dots, w_{km})$ : servem para ponderar cada variável de entrada, permitindo quantificar as suas relevâncias em relação à funcionalidade dos respectivos neurônios;
- Combinador linear  $(\sum w_{kj})$ : equivale ao corpo celular, sua função é somar todas as entradas ponderadas, com objetivo de produzir um valor para o potencial de ativação  $(u_k)$ ;
- Sinal de Saída  $(y_k)$ : representa o axônio, é o valor final podendo ser utilizado por outro neurônio;
- Bias  $(b_k)$ : representa uma constante de valor 1, que excita o neurônio por meio de uma polarização constante.

Matematicamente, o modelo apresentado na Figura 7 de um neurônio matemático pode ser representado pela Equação (1) e a RNA pela Equação (2) (HAYKIN, 2009):

$$u_k = \sum_{j=1}^m (w_{kj}x_j) \quad e \quad (1)$$

$$y_k = \varphi(u_k + b_k), \quad (2)$$

onde  $x_j = (x_1, x_2, \dots, x_m)$  são os sinais de entrada,  $w_{kj} = (w_1, w_2, \dots, w_m)$  são os pesos sinápticos ou pesos;  $b_k$  são as bias,  $y_k$  são os sinais de saída e  $\varphi$  é a função de ativação.

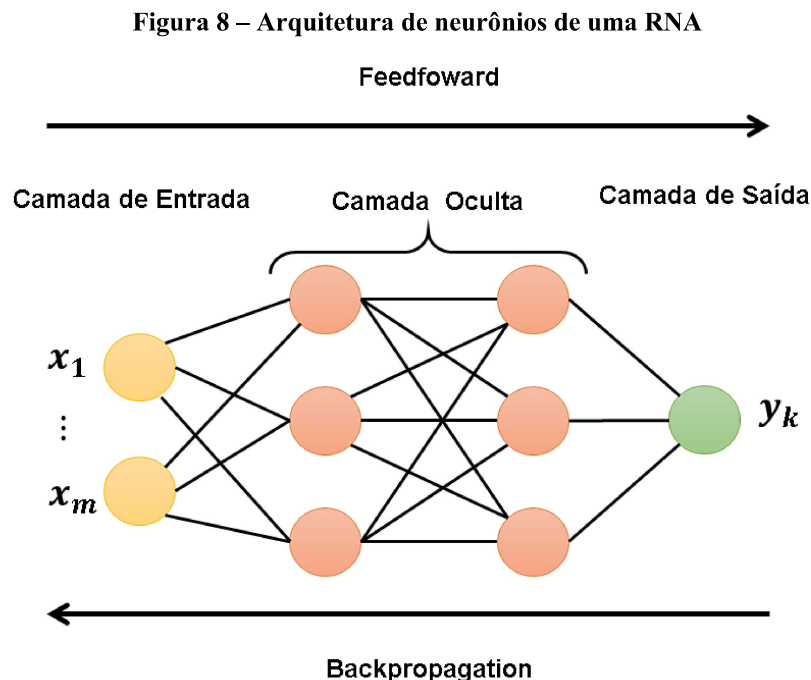
A função de ativação pode ter diferentes representações, os tipos básicos são: limiar, linear e sigmóide. De acordo com Pestana (2017) a escolha do tipo varia de acordo com o objetivo do projeto. As funções de ativação podem ser (KOPILER *et al.*, 2019; SANTOS, 2020):

**1) Diferenciáveis por partes** - são funções que possuem pontos cujas derivadas de primeira ordem não existem, as três principais funções desse grupo são: função degrau, degrau bipolar e rampa simétrica.

2) *Diferenciáveis* - são funções que possuem derivadas de 1ª ordem e estas são conhecidas em todos os pontos de seu domínio de definição. As três principais são: linear, sigmoideal logística e tangente hiperbólica.

### 2.3.1.2 Arquitetura e Treinamento das RNAs

A arquitetura de uma RNA é o modo como todos os neurônios estão estruturados e organizados. Historicamente, a primeira estrutura de um neurônio foi o *Perceptron*, que é composto apenas pelas camadas de entrada e saída, e são utilizados para classificar um conjunto de dados de forma linear (ARAÚJO, 2015). Essa estrutura foi aprimorada ao longo do tempo, como a necessidade de lidar com problemas não linearmente separáveis, acrescentando camadas intermediárias (ocultas), e criando assim, a estrutura chamada *Perceptron de Múltiplas Camadas* (*Multilayer Perceptron* - MLP), conforme ilustrado na Figura 8 (BRAGA; CARVALHO; LUDERMIR, 2000; MATA, 2011).



Fonte: Adaptado de Haykin (2009).

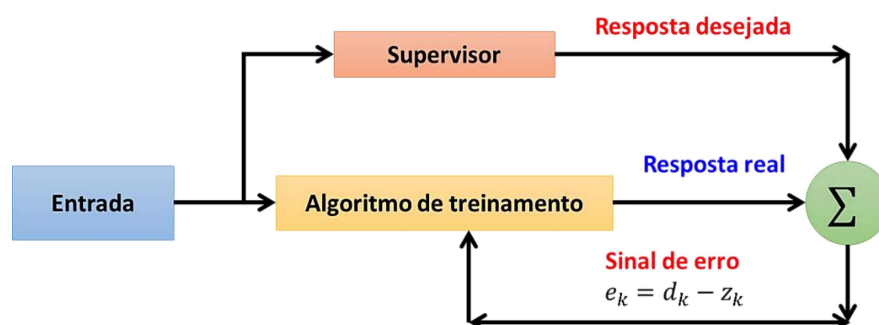
Na estrutura da RNA (Figura 8) as camadas de uma rede MLP são constituídas por três partes (CHOPRA *et al.*, 2018):

1. **Camada de entrada:** que são os dados ou sinais que alimentam a rede de entrada, onde os dados ou amostras são normalizados, com objetivo de melhorar o desempenho computacional durante o treinamento da rede;
2. **Camada intermediária ou oculta:** é onde ocorre o treinamento da rede ou ajuste dos pesos sinápticos entre as camadas. A função dos neurônios ocultos é intervir entre as camadas de entrada e saída, de modo a tornar a rede capaz de extrair estatísticas de ordem elevada;
3. **Camada de saída:** é responsável pela produção e apresentação dos resultados finais.

De acordo com Sipos *et al.* (2017) as redes MLP com treinamento supervisionado são do tipo *feedforward*, ou seja, o processamento da informação se dá no sentido progressivo através das ligações sinápticas entre os neurônios das camadas adjacentes. O treinamento de uma rede MLP depende da quantidade de camadas intermediárias. Para redes com mais de uma camada oculta o treinamento ocorre em duas fases, utilizando o processo de retropropagação do erro (*backpropagation*) (FURTADO, 2019; LORENZI; SILVA FILHO; CAMPAGNOLO, 2011).

Na fase de alimentação (*feedforward*) um padrão é apresentado às unidades da camada de entrada e, a partir desta camada, as unidades calculam sua resposta que é produzida na camada de saída, calculando um erro associado a este processo. Na fase retropropagação (*backpropagation*), o erro calculado é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas, vão sendo modificados através de um gradiente ( $\Delta w_{jk} = \eta \cdot \delta_j \cdot y_k$ ) (BKA *et al.*, 2021; FELIX; CARRAZEDO; POSSAN, 2017). Um exemplo desse processo é ilustrado na Figura 9.

Figura 9 – Treinamento de uma rede MLP *feedforward* - *backpropagation*



Fonte: Adaptado de BKA *et al.* (2021)

Na MLP, o sinal de erro ( $e_k$ ) do neurônio de saída ( $y_k$ ) na camada  $k$ , é definido pela Equação (3), onde  $e_k$  é a diferença da saída desejada ( $d_k$ ) pela saída real ( $z_k$ ). A função de erro total é apresentada na Equação (4) (HAYKIN, 2018):

$$e_k = d_k - z_k , \quad (3)$$

$$E_{TOTAL} = \frac{1}{2} \sum e_k^2 . \quad (4)$$

O aprendizado das redes consiste em alterar os pesos de forma a minimizar esta função de erro utilizando um gradiente descendente. Na fase de retropropagação, o erro entre a saída da rede e os valores de saída desejados é calculado usando a chamada regra delta generalizada, e os pesos entre os neurônios são atualizados da camada de saída para a camada de entrada da seguinte forma (HAYKIN, 2018):

$$w_{kj}^{m+1} = w_{kj}^m + \alpha \cdot \delta_j \cdot z_k + \beta \cdot w_{kj}^m , \quad (5)$$

onde  $\delta_j$  é o sinal de erro em um neurônio  $j$ ,  $z_k$  é a saída do neurônio  $j$ ,  $n$  é o número de iteração e  $\alpha$ ,  $\beta$  são chamados de parâmetro de taxa de aprendizado e fator de momentum, respectivamente.  $\delta_j$  na Equação (6) pode ser calculado usando a derivada parcial da função do erro na camada de saída e a na Equação (7) para as camadas ocultas, respectivamente, como segue (HAYKIN, 2018):

$$\delta_j = z_k \cdot (d_k - z_k) \cdot (1 - z_k) , \quad (6)$$

$$\delta_j = z_k \cdot (1 - z_k) \cdot \sum_k \delta_k \cdot w_{kj} , \quad (7)$$

onde a camada  $k$  significa a camada superior da camada  $j$ .

Um aspecto relevante relacionado ao projeto de redes MLP é o tipo de função de ativação utilizada. O cálculo do gradiente ( $\Delta w_{jk}$ ) para cada neurônio requer o conhecimento da derivada da função de ativação, e para que a derivada exista é imprescindível que a função seja contínua, sendo esse um requisito que a função de ativação deve atender (HAYKIN, 2018). Inúmeras funções de ativação são aplicadas para funções não lineares e diferenciáveis, mas uma das mais utilizadas é a função sigmóide, definida pela Equação (8) em que  $b > 0$ .

$$\varphi_j = \frac{1 - e^{(-\sum w_{jk} z_k + b)}}{1 + e^{(-\sum w_{jk} z_k + b)}}, \quad (8)$$

onde  $w_{jk}$  é o peso da conexão do neurônio  $i$  na camada inferior, para o neurônio  $j$  na camada superior,  $z_k$  é a saída do neurônio  $i$  e  $b$  é o valor de uma constante de polarização.

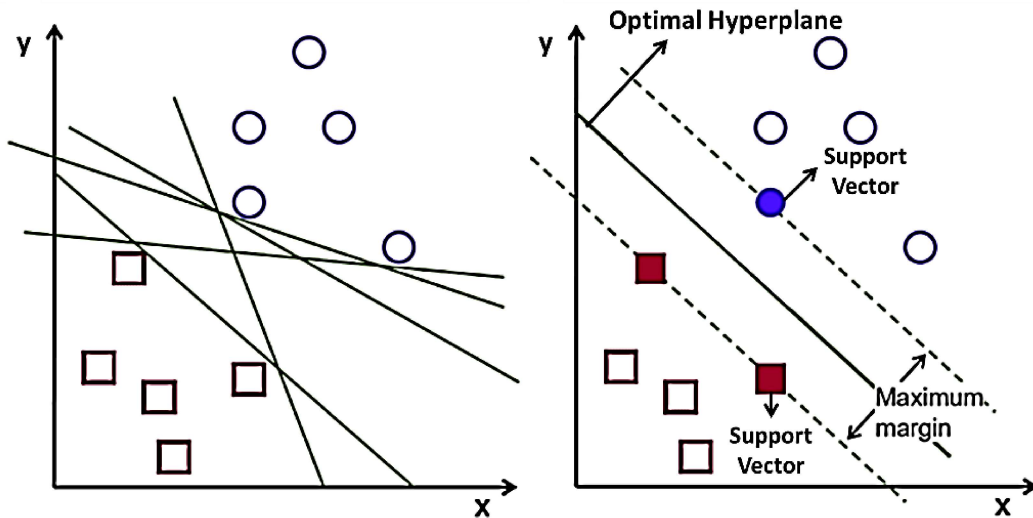
Outro importante parâmetro de avaliação para o algoritmo de *backpropagation* é a taxa de aprendizagem do modelo, que avalia a medida de rapidez com que o vetor de pesos será atualizado. A taxa de aprendizagem varia entre o intervalo [0,1] e quanto menor o parâmetro da taxa de aprendizado, menores serão as alterações nos pesos sinápticos (ROSA, 2020).

### 2.3.2 Máquina de Vetores de Suporte (*Support Vector Machine* – SVM)

Outra técnica de ML que tem uma ampla aplicação no estudo de resistência de concretos é o SVM. Diversas pesquisas foram desenvolvidas ao longo das últimas décadas aplicando este método em problemas lineares e não lineares de classificação, classificação não linear e regressão. O interesse pela aplicação do SVM frente a outros métodos no estudo de concretos é devido à sua boa capacidade de generalização e computação rápida (HUANG *et al.*, 2020; NGUYEN *et al.*, 2021b; OLALUSI; SPYRIDIS, 2020; PARK; YOON; OH, 2019; SADEGHIPOUR CHAHNASIR *et al.*, 2018; YAN; SHI, 2010; YANG; DONG, 2013).

O algoritmo de aprendizagem SVM é uma classe de técnicas de ML com alto poder e flexibilidade. O SVM representa uma generalização do algoritmo classificador de margem máxima, que por sua vez acomoda as fronteiras não lineares em problemas de classificação. O objetivo do algoritmo SVM é maximizar a margem, definida como a distância entre o hiperplano de separação, e as amostras de treinamento mais próximas deste hiperplano, que são os vetores de suporte (SAHA; DEBNATH; THOMAS, 2020; YU *et al.*, 2018; RASCHKA e MIRJALILI, 2017; JAMES *et al.*, 2013). A Figura 11 ilustra um exemplo de aplicação do SVM com a seleção dos vetores de suporte, o hiperplano ótimo e as margens maximizadas.

Figura 10 – Exemplo de aplicação do SVM destacando os vetores de suporte, o hiperplano ótimo e a margem maximizada



Fonte: Alvarez (2021)

A versão do SVM para análise de regressão é chamada de Vetores de Suporte para Regressão (SVR, do inglês *Support Vector Regression*). O SVR mapeia os vetores de entrada  $x = (x_1, \dots, x_m)$ , em um espaço de maior dimensão onde a máquina linear é construída pela minimização de um funcional regularizador. A máquina linear pode ser escrita como (CHANG; LIN, 2002; HAYKIN, 2018; SMOLA; SCHÖLKOPF, 2004):

$$\hat{y}(x) = (w \cdot x) + b, \quad (9)$$

onde  $\hat{y}$  é o valor aproximado de  $y$  em  $x$ ,  $w$  representa um vetor de pesos,  $b$  é um vetor de bias e  $(\cdot)$  é produto interno.

O SVR executa uma regressão linear utilizando uma função de perda  $\varepsilon$ -insensível  $L$ , dada por:

$$L(x) = \begin{cases} 0 & \text{se } |y(x) - \hat{y}(x)| \leq \varepsilon \\ |y(x) - \hat{y}(x)| & \text{caso contrário } \leq -\varepsilon \end{cases}, \quad (1)$$

enquanto tenta se reduzir a complexidade do modelo, minimizando o vetor de ponderação normalizado  $\|w\|$  em relação ao comprimento do vetor  $w$ . Incluindo as variáveis de folga não negativas  $\xi_i$  e  $\xi_i^*$ ,  $i = 1, \dots, m$  e a constante de penalização  $C$ , o problema de otimização pode ser formulado como:

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \cdot \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{sujeito a} \quad & \begin{cases} y_i - \hat{y}_i \leq \varepsilon + \xi_i^* \\ y_i - \hat{y}_i \geq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, \text{ para } i = 1, \dots, n \end{cases}, \end{aligned} \quad (2)$$

O problema de otimização não é resolvido em sua forma primal, ele pode ser transformado em um problema dual<sup>1</sup> (Equação 12):

$$\begin{aligned} \max \quad & -\frac{1}{2} \sum_{i=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) (x_i - x_i^*) - \varepsilon \sum_{i=1}^n (\alpha_i - \alpha_i^*) + \sum_{i=1}^n (\alpha_i - \alpha_i^*) \\ \text{sujeito a} \quad & \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ 0 \geq \alpha_i \geq C \text{ e } 0 \geq \alpha_i^* \geq C \end{cases}, \end{aligned} \quad (3)$$

onde  $\alpha_i$  e  $\alpha_i^*$  são os valores de limites inferiores dos vetores, o vetor de pesos  $w$  (Eq. 12) pode ser escrito como  $w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (x_i - x_i^*)$  e a saída estimada do SVR linear é dada por:

$$\hat{y}(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (x_i - x_i^*) + b. \quad (4)$$

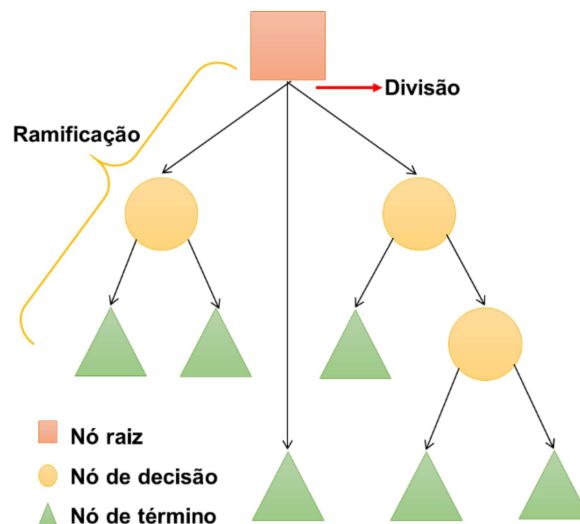
### 2.3.3 Árvore de Decisão (*Decision Tree* - DT)

Os algoritmos de aprendizagem baseados em árvores são considerados na atualidade um dos melhores e mais utilizados métodos de ML. Métodos como: árvore de decisão, floresta aleatória e *gradiente boosting* estão sendo muito usados para o estudo de resistência de concretos, devido a sua capacidade de alta precisão, estabilidade e facilidade de interpretação para problemas não lineares (CHOLLET, 2017; ERDAL, 2013; FENG i, 2020; HADZIMANYARKO *et al.*, 2020; HAN *et al.*, 2019; MA *et al.*, 2021; NUNEZ; NEHDI, 2021; WANG; GEEM; NAGAI, 2020).

<sup>1</sup>Dual ou princípio da dualidade: usado na matemática de otimização é o princípio de que os problemas podem ser vistos a partir de duas perspectivas: o problema primordial (primal) ou o problema dual. A solução para o problema dual fornece um limite inferior para a solução do problema primal (minimização). No entanto, em geral, os valores ótimos dos problemas primários e duais não precisam ser iguais. Sua diferença é chamada de diferença de dualidade.

Árvores de Decisão (do inglês *Decision Trees* - DT) é uma estrutura hierárquica composta por nós (raiz, ramos e folhas) conectados entre si, conforme ilustrado na Figura 11. O primeiro nó é chamado de raiz, que se localiza no topo da árvore. A partir do nó raiz, se estendem ramificações sucessivas denominadas ramos, que por sua vez, conectam os demais nós. Os últimos nós da árvore são denominados terminais ou folhas e representam uma decisão a ser tomada. Na estrutura de uma DT os nós internos são rotulados com atributos, as folhas são rotuladas com classes e os ramos são rotulados com valores (atributos categóricos) ou com intervalos (atributos numéricos).

**Figura 11 – Ilustração da estrutura de uma DT**



Fonte: Adaptado de SANTOS (2020)

Uma árvore decisória é uma representação visual de todos os possíveis caminhos de ações que se pode seguir para tomar uma decisão. O nó raiz ou de decisão representa uma decisão a ser tomada, o nó folha ou de probabilidade representa uma probabilidade ou uma condição, as ramificações representam o direcionamento à alguma alternativa e o nó final ou de resultado representa um resultado final ou uma consequência do problema.

O método toma como entrada uma situação descrita por um conjunto de atributos dada por um vetor ( $x_j$ ), executando uma sequência de testes (nó interno) e retorna uma decisão, podendo ser discretos (para classificação) ou contínuos (para regressão). Para problemas de regressão, os testes são quantitativos, utilizando os valores de saída ( $y$ ), definido pelos atributos de entrada em comparação a um valor de divisão. Normalmente o teste é definido comparando

se um valor é menor ou igual a outro. A partir de cada teste, é definido então os ramos da árvore, onde cada nó folha da árvore especifica o valor de retorno para um determinado dado de entrada. O valor de retorno de um determinado nó folha é dado pela média do valor de saída de todos os dados de teste que chegam ao nó. Matematicamente uma DT é definida como (Breiman *et al.*, 1984):

Dado um vetor de treinamento  $(x_j)$  com  $j = 1, \dots, m$  e um vetor de rótulo  $\theta$ , considere os dados do nó  $m$  representado pelas regiões  $Q_m$ , com  $N_m$  amostras. Para cada divisão de categoria  $\theta = (k, t_m)$ , consistindo em uma característica  $k$  e limiar  $t_m$ , os dados são particionados em sub-regiões representadas pelas Equações (14) e (15):

$$Q_m^i(\theta) = \{x, y | x_k \leq t_m\} , \quad (14)$$

$$Q_m^s(\theta) = \frac{Q_m}{Q_m^i(\theta)} , \quad (15)$$

onde  $Q_m^i$  é a sub-região inferior ao limiar  $t_m$ ,  $Q_m^s$  é a sub-região superior ao limiar  $t_m$ ,  $x$  o vetor de atributos,  $y$  o vetor de dados de saída e  $N_m$  o números de amostras categorizadas.

A qualidade de uma divisão de nó candidato  $m$  é então calculado usando a função de impureza  $H(\cdot)$ , dada pela Equação (16):

$$G(Q_m, \theta) = \frac{N_m^i}{N_m} \cdot H(Q_m^i(\theta)) + \frac{N_m^s}{N_m} \cdot H(Q_m^s(\theta)) , \quad (16)$$

Em seguida, é selecionado os parâmetros que minimizam a impureza, e a recursão da divisão para as sub-regiões  $Q_m^i(\theta^*)$  e  $Q_m^s(\theta^*)$  é feita até que a profundidade máxima permitida seja alcançada, considerando  $N_m < \min_{amostra}$  ou  $N_m = 1$ , calculada por:

$$\theta^* = \arg \arg \min_{\theta} \cdot G(Q_m, \theta) . \quad (17)$$

Os critérios de seleção para a melhor divisão são baseados em diferentes medidas, tais como: impureza, distância e dependência. O critério mais utilizado para problemas de regressão

é o de impureza, sendo usado o erro quadrático médio (MSE), erro absoluto médio (MAE) ou erro médio de Poisson, que serão descritos no capítulo 3.

Outro parte importante no processo de construção de uma árvore de regressão, é a poda, devido a existência de ruídos na base de dados, que faz com que as árvores induzidas classifiquem novos objetos de modo não confiável e tendam a ter uma grande estrutura tornando difícil a compreensão. O método de poda pode evitar problemas com ruídos ou erros nos ramos da árvore de regressão que levam ao *overfitting*. Os métodos de poda de uma árvore de regressão basicamente é:

- Pré-poda: realiza o procedimento durante a construção da árvore, onde o processo para de dividir os atributos e transforma o nó corrente em um nó folha da árvore;
- Pós-poda: realiza o procedimento após a construção da árvore, eliminando ramos completos, ou seja, os nós abaixo desse ramo são excluídos e transformados em um nó folha, que representará a classe mais frequente no ramo.

### 2.3.4 Métodos *Ensembles*

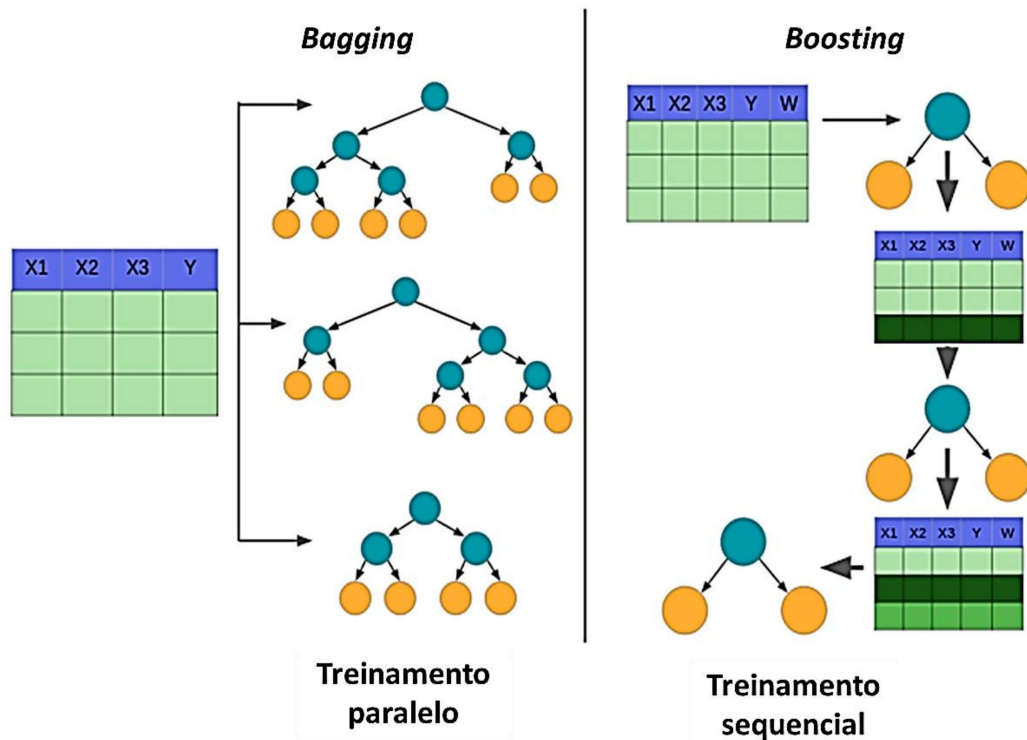
O aprendizado pelo método de *ensemble* consiste em combinações de modelos mais simples e de baixo poder preditivo, para resultar em um modelo mais forte com maior acurácia. Dentro da classe de modelos *ensembles* há duas técnicas comumente conhecidas como *bagging* e *boosting* que são utilizadas neste trabalho (CUTLER; CUTLER; STEVENS, 2012; DIETTERICH, 2000; IZBICKI; SANTOS, 2020).

Na metodologia *bagging* (*Bootstrap Aggregation*), proposta por Breiman (1996), os preditores são treinados separadamente e re-amostrados (*Bootstrap*) com reposição diversas vezes, e em seguida agrupados através de algum método de combinação. A precisão final do *bagging* é aumentada ao utilizar a média das predições (várias árvores neste caso) (LOUPPE; GEURTS, 2012).

Assim como o método *bagging*, no método *boosting* os preditores também são treinados por amostras individuais, com o crescimento de árvores sequencialmente, onde cada árvore construída é utilizada para a construção da árvore seguinte. No entanto, o método de combinação não é a média dos preditores, mas uma ponderação do desempenho de cada

modelo. De acordo com Schapire (2002), o método *boosting* é baseado na observação de que encontrar muitas hipóteses fracas com um preditor pode ser mais fácil do que encontrar uma única hipótese de predição com alta precisão (DRUCKER, 1997; SCHAPIRE, 2002). A Figura 12 apresenta uma ilustração de treinamento pelos métodos *bagging* e *boosting*.

Figura 12 – Ilustração de métodos *ensembles*



Fonte: Algoritma (2021)

As principais diferenças de desempenho desses dois métodos está ligada ao seu funcionamento, no qual no processo de *bagging* o treinamento é dado pela combinação de modelos independentes, o que pode generalizar o treinamento. Já no processo de *boosting*, o treinamento é dado por uma combinação dos modelos, normalmente gerada por uma aplicação de um fator entre cada iteração, minimizando assim as chances de generalização (*overfitting*) (DIETTERICH, 2000).

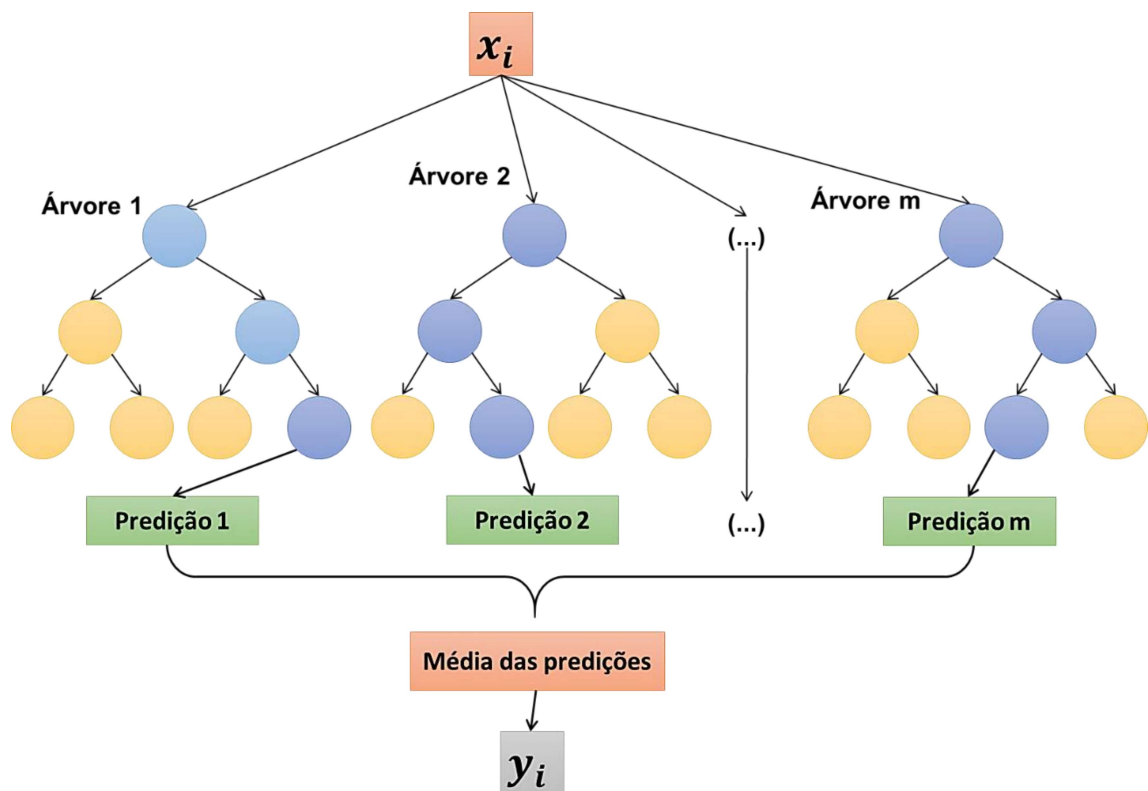
Dentro da classe dos modelos *bagging* e *boosting* foi utilizado neste trabalho os métodos Floresta Aleatória, *Adaboost*, *Gradient Boosting* e *XG Boosting* descritos a seguir.

### 2.3.5 Floresta Aleatória (*Random Forest* - RF)

Floresta Aleatória ou do inglês *Random Forest* (RF) é um modelo de ML baseado em árvores de decisão, que lida com conjunto de dados de alta dimensão e presença de multicolinearidade. Este tipo de modelo é usualmente utilizado não apenas para classificação, mas também para regressão, estudo de importância e seleção de variáveis e detecção de *outlier* (BIAU, 2012; BREIMAN, 2001).

O método RF está situado em uma subcategoria de estimadores *ensemble*, que tem como objetivo principal combinar todas as árvores predictoras de regressão, a fim de melhorar a generalização (IZBICKI; SANTOS, 2020). O algoritmo de aprendizagem RF utiliza um conjunto de árvores construídas a partir de um subconjunto de dados, baseado em uma premissa de que um conjugado de árvores detém melhores resultados que as árvores individuais, reduzindo assim a variação dos resultados (SAVARGIV; MASOUMI; KEYVANPOUR, 2021). A Figura 13 apresenta a arquitetura de uma RF de regressão.

Figura 13 – Ilustração da estrutura de uma RF de regressão



Fonte: Adaptado de Zhang, Li e Wang (2020).

O RF é um conjunto de  $B$  árvores  $\{T_1(x), \dots, T_B(x)\}$ , onde  $x \in (x_1, \dots, x_m)$  é um vetor  $m$ -dimensional de variáveis de um objeto classificado. O conjunto produz  $B$  saídas ( $\hat{y}_1 = T_1(x), \dots, \hat{y}_B = T_B(x)$ ), onde  $\hat{y}_b, b \in (1, 2, \dots, B)$ , é a previsão de um objeto classificado pela  $b$ -ésima árvore. As saídas de todas as árvores de decisão são agregadas para definir uma previsão final  $\hat{y}$ . No caso de problemas de classificação a saída  $\hat{y}$  é a classe prevista para a maioria das árvores, e para regressão  $\hat{y}$  é a média das previsões individuais de cada árvore calculada pela Equação (18) (BOCK *et al.*, 2019; BREIMAN, 2001; CUTLER, 2013; HO, 1995; ZHANG; LI; WANG, 2020).

$$\hat{f}_{RF}^B(x_i) = \frac{1}{B} \cdot \sum_{b=1}^B T_b(x_i), \quad (5)$$

onde,  $B$  é o número total de árvores,  $T()$  representa a resposta de uma árvore  $b$  para um vetor de entrada  $x_i$ .

### 2.3.6 Adaboost (*Adaptive Boosting*)

*Adaptive Boosting*, ou simplesmente *Adaboost*, é um método de conjunto que treina e implanta árvores de decisão em série. O algoritmo *Adaboost* consiste em combinar de forma sequencial vários modelos mais fracos de aprendizagem (*weak learner*), no qual a árvore subsequente leva em consideração as previsões da anterior, para formar um preditor mais conciso. O diferencial desse algoritmo é que as previsões mais difíceis (aquelas em que o *weak learner* da iteração atual mal previu) recebem um peso maior no preditor seguinte, buscando assim uma maior otimização do algoritmo final (COLLINS; SCHAPIRE; SINGER, 2002; SCHAPIRE, 2009; SOLOMATINE; SHRESTHA, 2004).

O algoritmo de aprendizado *Adaboost* toma como entrada uma sequência de amostras de treinamento  $S = \{(x_1, y_1), \dots, (x_m, y_m)\}$  em que cada instância  $x_i$  pertence a um domínio ou espaço de instância  $X$ , e cada rótulo  $y_i \in \{-1, +1\}$ . Assumindo um conjunto de funções de valor real em  $X$ , e hipóteses  $h_1, \dots, h_t$ , com  $t = 1, \dots, T$  denominadas de base de hipótese ou fraca. A forma como uma hipótese  $h$  ajusta as amostras de treinamento é determinada através de seu erro ( $\hat{\epsilon}$ ) de treinamento (erro empírico). Este erro é uma fração das  $m$  amostras que foram preditas incorretamente, como apresentado na Equação (19):

$$\hat{\varepsilon}(h) = \frac{1}{m} \sum_{i=1}^l l\{h(x_i) \neq y_i\}, \quad (6)$$

onde  $l\{\cdot\}$  é uma função que retorna um se o argumento é verdadeiro e zero caso contrário.

Usualmente se assume que as amostras de treinamento e de teste são geradas a partir de uma mesma distribuição  $D_t$  em pares  $(x, y)$ . A respeito dessa distribuição, o erro de teste esperado de uma hipótese  $h_t = X \rightarrow \{-1, +1\}$  é chamado de erro de generalização, que é igual à probabilidade ( $Pr$ ) de classificar de forma incorreta uma única amostra  $(x, y)$ . Para qualquer hipótese  $h$ , a medida monitorada será uma soma de eventos de erro dado pela Equação (20) (SCHAPIRE, 2009):

$$\varepsilon(h) = Pr_{(x,y) \sim w_t}[h(x) \neq y], \quad (20)$$

onde  $w_t$  é a distribuição de pesos atribuídas às amostras de treinamento;  $t$  é o período de aprendizagem para cada classificador fraco.

Procuram-se hipóteses fracas  $h_t$  que minimizem os erros  $\varepsilon_t$  ou, pelo menos, que cada hipótese obtenha um erro menor que  $\frac{1}{2}$ , a importância de um classificador fraco  $h_t$  é dada pela Equação (21), as novas atualizações dos pesos é calcula pela Equação (23), com um fator de normalização  $Z_t$ , obtendo finalmente o classificador forte pela combinação linear  $H(x)$  dada na Equação (24) (COLLINS; SCHAPIRE; SINGER, 2002).

$$\gamma_t = \frac{1}{2} \ln \left( \frac{1 - \varepsilon_t}{\varepsilon_t} \right), \quad (21)$$

$$w_{t+1}(i) = \frac{w_t(i) \exp(-\gamma_i \gamma_t h_t(x_i))}{Z_t}, \quad (22)$$

em que,

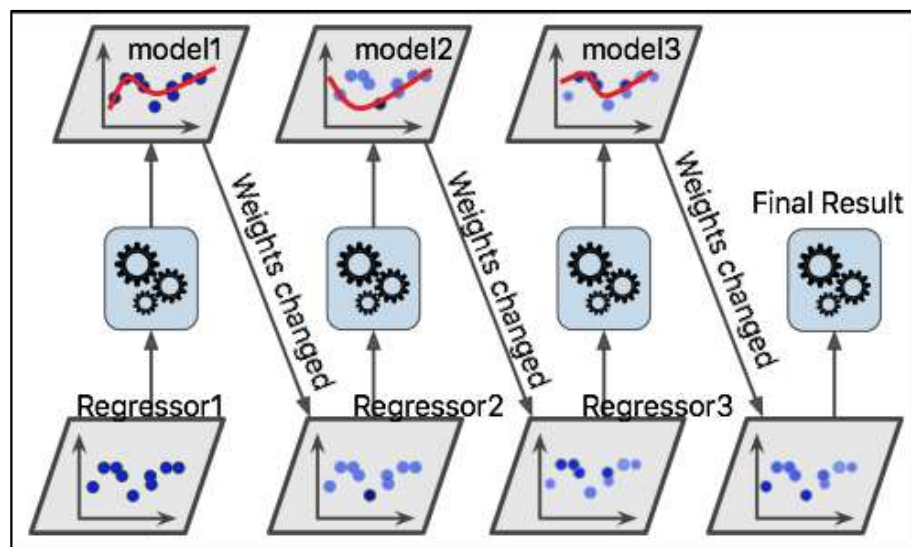
$$Z_t = \sum_{i=1}^n w_t(i) = 1, \quad (7)$$

$$H(x) = \text{sign}(\sum_{t=1}^T \gamma_t h_t(x)), \quad (8)$$

onde  $T$  é o número total de ciclos de aprendizagem (número de classificadores fracos);  $h_t$  são as hipóteses geradas a cada unidade de iteração ( $t$ );  $\varepsilon_t$  é o erro cometido durante a iteração;  $Z_t$  é o termo normalizador; e  $\gamma_t$  é a importância associada do classificador, calculada a partir do erro  $\varepsilon_t$ .

A Figura 14 apresenta uma ilustração do algoritmo *Adaboost* para problemas de regressão.

Figura 14 – Modelo do treinamento de um algoritmo *Adaboost*



Fonte: Sidhpuri (2021)

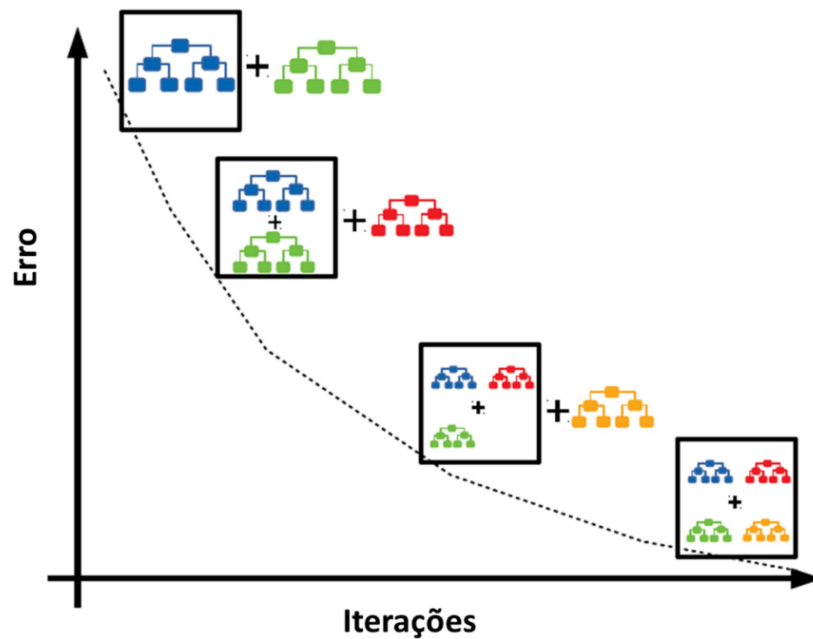
### 2.3.7 Gradient Boosting (GB)

Os algoritmos de *Gradient Boosting* é uma família de técnicas de aprendizagem de máquina que recentemente mostraram-se muito positivas no estudo de resistência mecânica de concretos (CUI *et al.*, 2021; ERDAL; KARAKURT; NAMLI, 2013; MARTINI, 2019; NGUYEN-SY *et al.*, 2020; NGUYEN *et al.*, 2021a; NUNEZ; MARANI; NEHDI, 2020; NUNEZ; NEHDI, 2021).

Os termos *boosting* (impulso) e *gradient* (gradiente) podem ser interpretados a partir da idealização de um algoritmo de otimização que opera sob uma ou várias funções de perda. A técnica de GB é uma combinação de diferentes modelos para produzir previsões, uma vez que

usa dois algoritmos: árvores de regressão e *boosting*, este último que constrói e combina os modelos. A Figura 15 apresenta um exemplo do treinamento das árvores do algoritmo GB.

Figura 15 – Exemplo de treinamento do algoritmo GB



Fonte: Pal (2020)

As árvores de regressão dividem o espaço de predição em retângulos com base nas variáveis independentes, ajustando uma constante em cada subespaço (FRIEDMAN, 2001). A variável independente e os pontos de divisão binários são escolhidas de forma a minimizar a entropia do modelo. A árvore de regressão cresce com a adição de novas variáveis ou novos pontos de divisão até que um critério seja alcançado. As árvores de decisão tendem a gerar sobreajuste (*overfitting*), e para solucionar este problema, o GB é implementado com uma função erro (FRIEDMAN, 2002; NATEKIN; KNOLL, 2013; NGUYEN *et al.*, 2021a).

O GB constrói um modelo de regressão ajustando sequencialmente uma função de aprendizado simples, em que o método dos mínimos quadrados é utilizado a cada iteração. Ao final do algoritmo, é gerada a função de estimação (FRIEDMAN, 2002). Para realizar estimações de funções é necessário uma variável de saída (*output*)  $Y$  e um conjunto de variáveis de entrada (*input*)  $X$ . A partir de um conjunto de treinamento  $T = \{x_i, y_i\}_1^N$  e uma função de perda  $L(y_i, y)$ , estimadora dos parâmetros dessas aproximações ajustando os dados.

Algoritmos de aprendizado usualmente realizam otimização sobre uma função de perda específica, sendo  $y_i$  o valor observado e  $y$  o valor predito (FRIEDMAN, 2002; HEPP *et al.*, 2016; HUANG *et al.*, 2019; THOMAS *et al.*, 2018). O algoritmo GB funciona seguindo os passos:

Primeiro passo iniciar o modelo com valor constante:

$$F_0(x) = \operatorname{argmin} \sum_{i=1}^n L(y_i, y), \quad (9)$$

onde  $y_i$  é o valor observado e  $y$  são os valores preditos.

A Equação (25) significa que é necessário encontrar o valor predito que minimize esta soma. O  $F_0(x)$  representa apenas uma folha da árvore. O passo seguinte é o processo de iteração de todas as  $M$  árvores, iniciando com a primeira árvore  $m = 1$ . Dentro desta iteração, é calculado o valor do resíduo  $r_{im}$  e a diferença entre o valor observado e o predito para cada amostra (Equação 26).

$$r_{im} = \left[ \frac{L(y_i, F(x_i))}{F(x_i)} \right], \quad (26)$$

São então  $m$  amostras para  $i = 1, \dots, m$ ; onde  $m$  é o número de amostras, esta equação representa o GB. Posteriormente, dentro do processo iterativo é feito o ajuste de uma árvore de regressão aos valores  $r_{im}$  e criam-se regiões terminais  $Q_{jm}$  para cada folha na nova árvore, usando atributos para prever os resíduos  $r$ . A seguir, para cada folha  $j$  na nova árvore para  $j = 1, \dots, j_m$ , calcula-se:

$$y_{jm} = \operatorname{argmin} \sum_{x_i \in Q} L(y_i, F_m(x_i) + y), \quad (27)$$

O valor de saída para cada folha que minimiza a soma, a última etapa do laço iterativo atualiza a função  $F_m$  (Equação 28), que é feita a nova predição para cada amostra utilizando a predição anterior  $F_{m-1}(x)$ .

$$F_m = F_{m-1}(x_i) + v \sum_{i=1}^{j_m} y_{jm}. \quad (28)$$

Nesta etapa, é usado o coeficiente de aprendizado  $\nu$  redutor do efeito que cada árvore tem na perda final e tende a melhorar a acurácia a longo prazo. Finalmente, com o fim do ciclo de iteração, retorna-se o valor final de  $F_M(x)$  da última árvore.

### 2.3.8 XGBoosting (XGB)

O *XGBoosting* ou do inglês *Extreme Gradient Boosting* é um algoritmo de aprendizado de máquina baseado no método de decisão de árvore com um processo de promoção de gradiente. É um dos algoritmos de aprendizado de máquina de maior sucesso no momento e tem sido amplamente utilizado por pesquisadores em algumas competições de aprendizado de máquina, atribuindo ao seu excelente desempenho de aprendizagem e rápida velocidade de cálculo, ainda mais usado do que o método popular de rede neural profunda (CHEN; GUESTRIN, 2016; CHEN; HE, 2014; CUI *et al.*, 2021).

Modelos *XGBoosting* contudo, diferem de outras técnicas de *Gradient Boosting* pois empregam um algoritmo sensível à dispersão na busca por ramificações, que torna a complexidade computacional do modelo linear ao número de observações não ausentes. Assim como integram otimização do uso de recursos que permitem calcular paralelamente a aptidão dos atributos (CHEN; GUESTRIN, 2016).

De forma geral, o *XGBoosting* é um método que implementa o algoritmo de árvore de decisão do GB proposto por Friedman (2001), onde um conjunto  $t$  de modelos é treinado sequencialmente, sendo que o modelo  $t$  tem como objetivo corrigir os erros do modelo anterior  $t - 1$  (HUANG *et al.*, 2019). Matematicamente este método funciona da seguinte maneira:

Seja  $y_i$  o valor do observado e  $\hat{y}_i^t$  o valor predito do  $t - \text{ésimo}$  modelo para a amostra  $x_i$ . Se  $l$  é uma função de erro qualquer e  $n$  é o número total de amostras, a função perda ( $L$ ) na iteração  $t$  é definido como (CHEN; GUESTRIN, 2016):

$$L_t = \sum_{i=1}^n l(y_i, \hat{y}_i^t), \quad (29)$$

Como o modelo foi construído de forma iterativa, temos que a predição na iteração  $t$  é equivalente à predição na iteração  $t - 1$  somada à predição de um novo modelo  $f_t$ , conforme

apresentado na Equação (30). Adicionando um termo de regularização  $\Omega$  na Equação (31) para ajudar a controlar a complexidade do modelo, tem-se (Equação 32):

$$\hat{y}_i^t = \hat{y}_i^{t-1} + f_t(x_i) \quad , \quad (10)$$

$$L_t = \sum_{i=1}^n l(y_i, \hat{y}_i^t + f_t(x_i)) \quad , \quad (11)$$

$$L_t = \sum_{i=1}^n l(y_i, \hat{y}_i^t + f_t(x_i)) + \Omega(f_t) \quad . \quad (12)$$

Para que ocorra o acerto de cada árvore adicionada, devemos tomar a função  $L$  como um problema de otimização, ou seja, queremos encontrar o  $f_t$  que minimiza  $L$ . Aplicando a Série de Taylor, de modo a tornar a função  $L$  infinitamente diferenciável, escrevendo a função na ordem 2 e substituindo as derivadas parciais pelo gradiente ( $g_i$ ) e o hessiano ( $h_i$ ), tem-se:

$$L_t \approx \sum_{i=1}^n \left[ l(y_i, \hat{y}_i^t) + g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 \right] + \Omega(f_t) \quad , \quad (13)$$

em que,

$$g_i = \frac{\partial l(y_i, \hat{y}_i^t)}{\partial (\hat{y}_i^t)} \quad \text{e} \quad h_i = \frac{\partial^2 l(y_i, \hat{y}_i^t)}{\partial (\hat{y}_i^t)^2} \quad . \quad (14)$$

Como  $l$  é uma constante e o nosso objetivo é encontrar o  $f_t$  que minimiza a Equação (33), não precisamos do termo  $l$ . Assim, tem-se que a função perda é dada pela Equação (35).

$$L_t \approx \sum_{i=1}^n \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 \right] + \Omega(f_t) \quad (35)$$

### 2.3.10 K-Vizinhos Mais Próximos (*K-Near Neighbor* – KNN)

O método dos k-vizinhos mais próximos (em inglês *k-nearest neighbours* - KNN) é um dos métodos mais populares na comunidade de aprendizado de máquina (HADZIMANYARKO *et al.*, 2020; IZBICKI; SANTOS, 2020). O KNN é um algoritmo simples que armazena todos os casos disponíveis e prevê o alvo numérico com base em uma medida de similaridade (por exemplo, funções de distância). Ele tem como base estimar a função de regressão  $g(x)$  para uma dada configuração das covariáveis  $x$  com base nas respostas  $y$  dos

KNN a  $x$  (IZBICKI; SANTOS, 2020; SHALEV-SHWARTZ; BEN-DAVID, 2013). Formalmente, definimos:

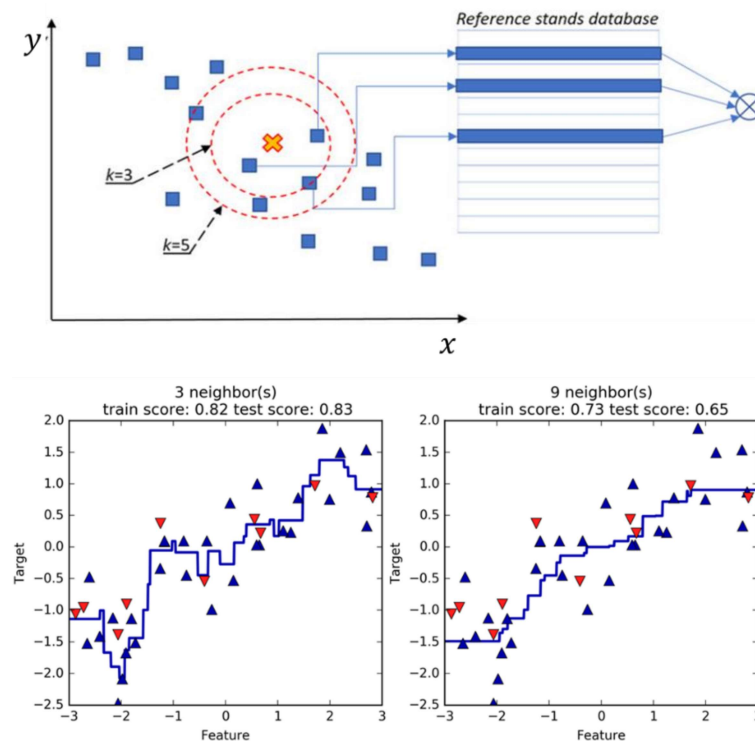
$$g(x) = \frac{1}{k} \sum_{y \in N_x} (y_i) \quad e \quad (36)$$

$$N_x = \{i \in \{1, \dots, n\} | d(x_i, x) \leq d_x^k\}, \quad (37)$$

onde  $N_x$  é o conjunto das  $k$  observações mais próximas de  $x$ , e  $d_x^k$  é a distância do  $k$  – éximo vizinho mais próximo de  $x_i$  a  $x$ .

Em palavras, a função de regressão avaliada em  $x$  é estimada utilizando-se uma média local das respostas dos KNN a  $x$  no espaço das covariáveis. A Figura 16 apresenta uma ilustração do treinamento de um algoritmo KNN de regressão, onde ilustra a importância do ajuste do parâmetro  $k$  durante o treinamento do algoritmo.

Figura 16 – Exemplo do treinamento de um algoritmo KNN para regressão, variando a quantidade vizinhos



Fonte: Muhajir (2019)

Uma implementação simples da regressão KNN é calcular a média do alvo numérico dos K-vizinhos mais próximos. Outra abordagem usa uma média ponderada de distância inversa dos K-vizinhos mais próximos. A regressão KNN usa as mesmas funções de distância da classificação KNN que são:

$$\text{Euclidiana: } d_E = \sqrt{\sum_{i=1}^k (x_i - y_i)^2}, \quad (15)$$

$$\text{Manhattan: } d_{Ma} = \sum_{i=1}^k |x_i - y_i|, \quad (16)$$

$$\text{Minkowski: } d_{Mi} = \left( \sum_{i=1}^k |x_i - y_i|^q \right)^{\frac{1}{q}}. \quad (17)$$

### 2.3.11 Regressão Linear Múltipla (RLM)

A RLM é um modelo estatístico que estabelece a relação entre uma variável de resposta (variável dependente denotada por  $y$ ) e várias variáveis preditoras ou explicativas (variáveis independentes denotadas por  $(x_1, x_2, \dots, x_p)$ ), ou seja, é uma relação matemática que permite analisar o efeito de mais de uma variável independente na resposta ao mesmo tempo. De acordo com Yan e Su (2009) a RLM pode ser usada para examinar o quanto um determinado conjunto de variáveis independentes podem explicar suficientemente o resultado de um problema, ou ainda em outros casos, a RLM é usada para examinar o efeito do quanto as variáveis independentes podem influenciar no seu resultado (JAMES *et al.*, 2013).

A RLM utiliza uma forma linear para a função de predição, ou seja, a função de predição de regressão linear múltipla para  $p$  variáveis explicativas pode ser escrita como (CHEIN, 2019; YAN; SU, 2009):

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \varepsilon, \quad (41)$$

onde  $y$  é a variável dependente,  $\beta_0$  é o intercepto que indica onde a reta cruza o eixo  $y$ ,  $\beta_1, \dots, \beta_p$  são os coeficientes estimadores de regressão,  $x_1, x_2, \dots, x_p$  são as variáveis independentes,  $\varepsilon$  o erro que apresenta distribuição normal com média zero e variância  $\sigma^2$ .

O resultado do modelo apresentado na Equação (41) é um único valor que representa uma combinação do conjunto inteiro de variáveis que melhor atinge o objetivo da análise multivariada específica. A solução de ajuste da reta pode ser generalizada a um conjunto de pontos  $(x_1, y_1), \dots, (x_n, y_n)$ , pelo método de mínimos quadrados (MMQ), que minimiza a soma de quadrados dos resíduos ( $\varepsilon$ ), ou pelo método de máxima verossimilhança (MMV), que maximiza a probabilidade de ocorrência da variável dependente ( $y$ ), para que os modelos de regressão múltipla possam ser utilizados. Os coeficientes  $\beta$  são estimados utilizando o MMQ, pela Equação (42):

$$\hat{\beta} = \operatorname{argmin}_{\beta} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{1i} - \dots - \beta_n x_{pi})^2 \quad (42)$$

A RLM envolve questões importantes no qual alguns critérios devem ser verificados para que um modelo de regressão seja válido, como (MONTGOMERY; PECK; VINING, 2012; MENDONÇA, 1998; BATISTA, 2004):

- a) **Linearidade** - as transformações de variáveis, às vezes são necessárias em busca da linearidade, variância não constante dos erros e não normalidade dos erros, obtendo-se um modelo mais simples.
- b) **Normalidade dos resíduos:** a verificação da normalidade dos resíduos pode ser realizada por uma das formas a seguir: a) pelo exame de histograma dos resíduos amostrais padronizados, com o objetivo de verificar se sua forma guarda semelhança com a da curva normal; b) pela análise do gráfico de resíduos padronizados versus valores ajustados, que deve apresentar pontos dispostos aleatoriamente, com a grande maioria situados no intervalo  $[-2;+2]$ ; c) pela comparação da frequência relativa dos resíduos amostrais padronizados nos intervalos de  $[-1;+1]$ ,  $[-1,64;+1,64]$  e  $[-1,96;+1,96]$ , com as probabilidades da distribuição normal padrão nos mesmos intervalos, ou seja, 68 %, 90 % e 95 %; d) pelo exame do gráfico dos resíduos ordenados padronizados versus distribuição normal padronizada, que deve se aproximar da bissetriz do primeiro quadrante; e) pelos testes de aderência não-paramétricos (Qui-Quadrado, Kolmogorov-Smirnov e Jarque-Bera).
- c) **Homocedasticidade:** a variação constante (homogênea) é uma condição fundamental dentro da teoria das regressões o que garante que a estimativa da variável dependente não sofrerá perturbações. Em casos de variação não constante (heterocedasticidade), os

coeficientes da regressão serão afetados pelos valores extremos das variáveis independentes.

- d) **Autocorrelação dos erros:** a autocorrelação dos erros decorre da influência sobre os resíduos das variáveis independentes importantes que não são consideradas na equação e, quando a equação possui resíduos independentes ele não sofrerá perturbações.
- e) **Pontos influenciantes (*outliers*):** são pontos atípicos em relação aos outros elementos do estudo, ocasionando irregularidade no modelo. A verificação destes pontos deve ser feita analisando o gráfico dos resíduos versus cada variável independente, e também em relação aos valores ajustados.

### 2.3.11.1 Regressão Polinomial

Um padrão comum no aprendizado de máquina é usar modelos lineares treinados em funções que não apresentam uma relação linear entre os dados de entrada e saída. Essa abordagem mantém o desempenho geralmente rápido dos métodos lineares, enquanto permite que eles se ajustem a uma gama muito mais ampla de dados. Existem muitos casos em que o modelo obedece a um comportamento polinomial, sendo assim necessário adaptar o ajuste para uma função polinomial de grau superior a partir dos coeficientes (BATISTA, 2004).

Analogamente aos conceitos de RLM, temos que o procedimento dos MMQ pode ser prontamente estendido para ajustar os dados por um polinômio de grau mais alto. A regressão para um polinômio de grau  $k$  ( $i = 1, \dots, k$ ), pode ser representada como na Equação (43):

$$y = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 \dots + \beta_k x_i^k + \varepsilon . \quad (43)$$

Tem-se ainda, que determinar os coeficientes de um polinômio de grau  $k$ , é equivalente a resolver um sistema de  $k + 1$  equações lineares simultâneas. Nesse caso, os coeficientes do ajuste polinomial de grau  $k$  serão dados pela relação (BATISTA, 2004):

$$X^T X \beta = X^T Y , \quad (44)$$

onde a matriz  $X$  é uma matriz de Vandermonde de grau  $k$  que contém  $n$  linhas e  $k + 1$  colunas:

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{1n}^k \\ 1 & x_{12} & \dots & x_{2n}^k \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1n} & \dots & x_{nn}^k \end{bmatrix}$$

### 2.3.11.2 Mínimos Múltiplos Ordinários (MQO)

O método dos Mínimos Quadrados Ordinários (MQO) é uma técnica de otimização matemática que procura encontrar o melhor ajuste para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças, entre o valor estimado e os dados observados (CHEIN, 2019). A partir do modelo de regressão linear múltipla (Eq. 45) e dos resíduos estimados (Eq. 46), podemos elencar as propriedades numéricas do estimador de MQO (CHEIN, 2019).

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} \dots + \hat{\beta}_k x_{ki} + \varepsilon_i, \quad (45)$$

$$\hat{\varepsilon}_i = Y_i - \hat{Y}_i, \quad (46)$$

onde  $y_i$  são os valores das variáveis dependentes observadas,  $x_{ki}$  são os valores das variáveis independentes,  $\hat{\beta}$  são os coeficientes da regressão a serem estimados e  $\varepsilon_i$  os resíduos. Para a correta aplicação do modelo MQO, se exige os seguintes pressupostos (CHEIN, 2019):

1. A soma dos resíduos é igual a 0;
2. Os estimadores  $\bar{y}_i$  e  $\bar{\hat{y}}_i$  de MQO satisfazem as equações normais e  $\bar{y}_i = \bar{\hat{y}}_i$ ;
3. A covariância amostral entre cada variável independente e os resíduos de MQO é zero  $\sum_{i=1}^n (\hat{\varepsilon}_i x_{ij}) = 0, j = 1, \dots, k$ ;
4. O ponto  $(\bar{x}_1, \bar{x}_2, \dots, \bar{x}_k, \bar{y})$  sempre está na reta de regressão de MQO:  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}_1 + \hat{\beta}_2 \bar{x}_2 \dots + \hat{\beta}_k \bar{x}_k$ .

### 2.3.12 Regressão Ridge

A regressão Ridge é um modelo estatístico que também busca minimizar a soma do erro quadrático médio (Eq. 47), como uma alternativa ao método comum de mínimos quadrados (MMQ) (MONTGOMERY; PECK; VINING, 2012).

$$SQE = \sum (y_i - \hat{y}_i)^2 \quad (47)$$

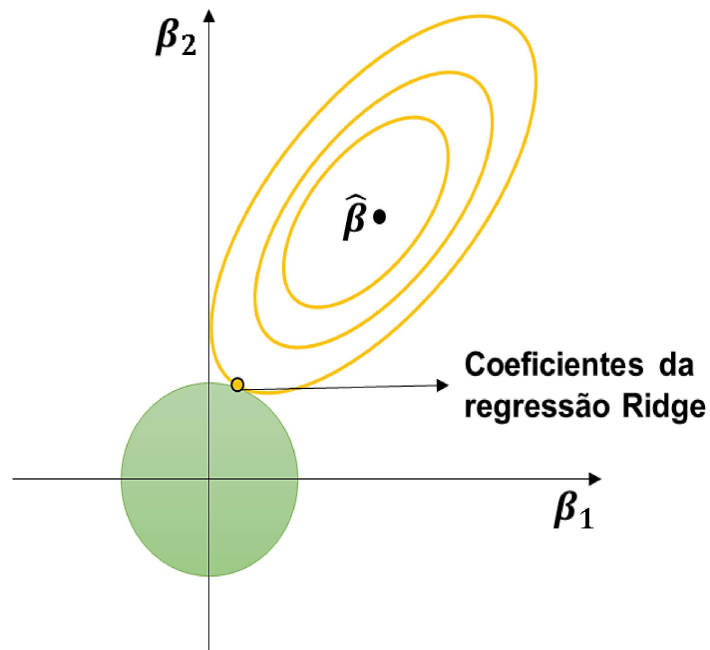
De acordo com Mangalathu e Jeon (2018) a regressão MMQ é extremamente sensível e propensa a erros quando as variáveis de estudo apresentam multicolinearidade, e para estabilizar os sistemas de estudo, a regressão ridge penaliza os coeficientes através da sua função objetivo. Pelo fato de ser penalizada pela norma  $L_2$  do vetor de coeficientes, se diz que a regressão Ridge é uma regressão regularizada em  $L_2$ . Na regressão Ridge isso é feito encontrando-se o estimador dado pela Equação (48) (IZBICKI; SANTOS, 2020):

$$\hat{\beta}_{ridge} = \operatorname{argmin}_{\beta} \sum_{k=1}^n (y_k - \beta_0 - \sum_{j=1}^p \beta_j x_{kj})^2 + \lambda \sum_{j=1}^p \beta_j^2, \quad (18)$$

em que  $\lambda$  é um número real positivo,  $L_2$  indica o fato de estar medindo a complexidade de um vetor  $\beta$  usando sua norma em  $L_2$ ,  $\|\beta\|_{L_2}^2 = \sum_{j=1}^p (\beta_j^2)$ .

A regressão Ridge impõe sobre o vetor de coeficientes uma condição de contorno esférica (Figura 17) e consegue assim diminuir de maneira consistente a variância de modelos lineares com os coeficientes calculados. Do mesmo modo, também corrige os sinais dos coeficientes calculados, de maneira que os estimadores possuam um comportamento convergente com o aumento de  $\lambda$ .

Figura 17 - Condição de Contorno para Regressão Ridge



Fonte: Adaptado de Bishop (2006)

### 2.3.13 Regressão LASSO

A regressão LASSO ou do inglês *Least Absolute Shrinkage and Selection Operator* (LASSO) é um modelo linear que estima coeficientes esparsos. Assim como a regressão Ridge, o método LASSO consiste em encontrar uma solução  $\beta$  que minimize a soma de seu erro quadrático médio (MMQ) com uma medida de complexidade de  $\beta$ , mas inclui a seleção e regularização de variáveis para aumentar a precisão da predição e a interpretabilidade do modelo de regressão (IZBICKI; SANTOS, 2020; MANGALATHU; JEON, 2018).

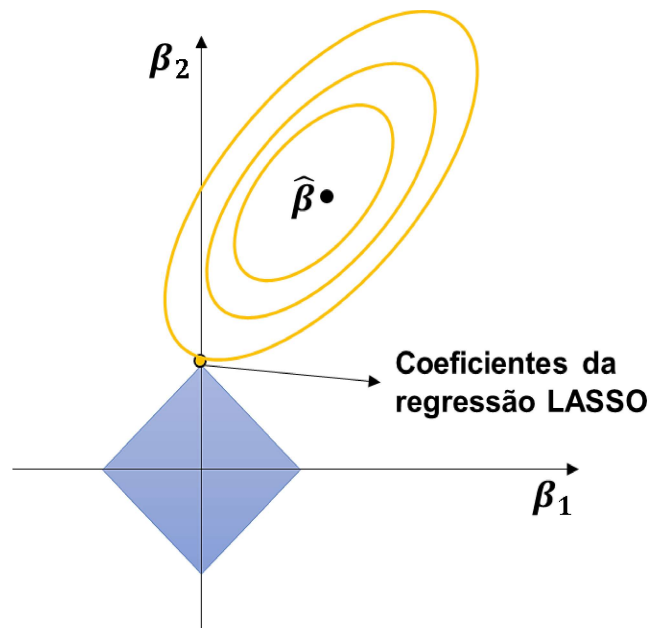
A variável dependente é estimada através de somas lineares, que possui uma regularização de norma  $L_1$  do vetor dos coeficientes, que funciona também como um selecionador de variáveis. Para esse problema quando  $\lambda$  tende a zero, o problema se torna um problema ordinário de regressão e, quando  $\lambda$  tende a valores maiores, resta somente o coeficiente linear. A função objetivo é dada pela Equação (49) (IZBICKI; SANTOS, 2020):

$$\hat{\beta}_{Lasso} = \operatorname{argmin}_{\beta} \sum_{k=1}^n (y_k - \beta_0 - \sum_{j=1}^p \beta_j x_{kj})^2 + \lambda \sum_{j=1}^p |\beta_j|, \quad (49)$$

em que  $\lambda$  é um número real positivo,  $L_1$  indica o fato de que estamos medindo a esparsidade de um vetor  $\beta$  usando sua norma em  $L_1$ ,  $\|\beta\|_{L_1} = \sum_{j=1}^p |\beta_j|$ .

A Figura 18 apresenta uma ilustração dos contornos das funções de erro e suas restrições. As formas geométricas representam as áreas de restrições e as curvas de níveis representam as funções de erro de mínimos quadrados.

**Figura 18 - Condição de Contorno para Regressão LASSO**



Fonte: Adaptado de Bishop (2006)

### 2.3.14 Regressão Bayesiana

Em teoria das probabilidades e estatística, o teorema de Bayes descreve a probabilidade de um evento, baseado em um conhecimento a priori que pode estar relacionado ao evento. O teorema mostra como alterar as probabilidades a priori tendo em vista novas evidências para obter probabilidades a posteriori (EHLERS, 2003).

Como citado anteriormente, nos modelos lineares para regressão o MMQ ou de máxima verossimilhança (MMV), pode levar a graves problemas de *overfitting* se os modelos complexos forem treinados usando conjuntos de dados de tamanho limitado. Buscando a solução que minimiza a função de erro regularizada em relação ao vetor de peso  $w$  e o

coeficiente de regularização  $\lambda$ , o tratamento bayesiano de regressão linear é um método que evita o problema de *overfitting* de probabilidade máxima e que leva a métodos automáticos de determinação da complexidade do modelo usando apenas os dados de treinamento (BISHOP, 2006).

A técnica de regressão bayesiana pode ser usada para incluir parâmetros de regularização no procedimento de estimativa. O parâmetro de regularização não é definido em sentido rígido, mas sintonizado com os dados disponíveis, ou seja, ele pode ser feito pela introdução de um *priori* não informativo sobre os hiperparâmetros do modelo. O regularizador  $L_2$ , usado na regressão Ridge é equivalente a encontrar uma estimativa máxima posteriori sob um Gaussiano *priori* sobre os coeficientes  $w$  com precisão  $\lambda^{-1}$ . Em vez de definir  $\lambda$  manualmente, é possível tratá-lo como uma variável aleatória a ser estimada a partir dos dados (BISHOP, 2006).

Para obter um modelo totalmente probabilístico, os valores de saída  $y$  é assumido como uma distribuição Gaussiana em torno  $X_\beta$ , tal que (BISHOP, 2006; TIPPING, 2001):

$$p(y|X, w, \alpha) = N(y|X_w, \alpha) , \quad (50)$$

onde  $p$  é a distribuição de probabilidade *posteriori* dos parâmetros do modelo,  $\alpha$  é uma variável aleatória estimada a partir dos dados, e  $N$  representa a distribuição normal dos parâmetros do modelo.

Um dos tipos mais úteis de regressão Bayesiana é a regressão Bayesian Ridge, que estima um modelo probabilístico do problema de regressão. A regressão Bayesiana Ridge estima um modelo probabilístico do problema de regressão conforme descrito acima. O *priori*  $w$  para o coeficiente é dado por um gaussiano esférico conforme apresentado na Equação (51):

$$p(w|\lambda) = N(w|0, \lambda^{-1}I_p) . \quad (51)$$

Os *prioris* sobre  $\alpha$  e  $\lambda$  são escolhidos para serem distribuições  $\lambda$ , o conjugado *priori* para a precisão do Gaussiano. O modelo resultante é denominado Regressão Bayesiana Ridge e é semelhante ao Ridge clássico. Os parâmetros  $w$ ,  $\alpha$  e  $\lambda$  são estimados conjuntamente durante

o ajuste do modelo, os parâmetros de regularização  $\alpha$  e  $\lambda$  sendo estimados pela maximização da MVS.

## 2.4 Análise Discriminante

O método de análise discriminante é uma técnica da estatística multivariada que tem por objetivo determinar as variáveis que diferenciam ou discriminam grupos, permitindo assim a identificação de grupos similares e a classificação de novos casos, em que a inserção desses elementos ocorre no grupo a que o elemento tem a maior probabilidade de pertencer (MAIA; IAROSINSKI NETO, 2016).

Segundo Naresh (2008) o problema da discriminação entre dois ou mais grupos, foi inicialmente abordado por Fisher (1936), para encontrar uma combinação linear de recursos que caracterizam ou separam duas ou mais classes de objetos ou eventos. A combinação resultante é usada como um classificador linear ou, mais comumente, para a redução da dimensionalidade antes da classificação posterior.


Os pré-requisitos básicos para o uso deste método são que existam dois ou mais grupos e que supostamente suas variáveis difiram entre si, e que estas possam ser medidas no intervalo ou nível de razão. A análise discriminante permite analisar as diferenças entre os grupos e nos fornece um meio de atribuir (classificar) qualquer caso ao grupo em que mais se assemelhe. A análise discriminante é aplicável quando a variável dependente ou o critério é categórico e as variáveis preditoras ou independentes são contínuas. Os objetivos da análise discriminante são os seguintes (MAIA; IAROSINSKI NETO, 2016):

1. Desenvolver funções discriminantes ou combinações lineares de variáveis preditoras ou independentes, que fazem uma melhor diferenciação entre as categorias das variáveis dependentes ou critérios (grupos). O número de funções equivale ao número de grupos menos 1 (ex.: 3 grupos = 2 funções);
2. Examinar se existem diferenças significativas entre os grupos, em termos das variáveis preditivas;
3. Determinar quais variáveis preditivas contribuem mais para as diferenças entre os grupos;

4. Classificar os casos em um dos grupos com base nos valores das variáveis preditivas;
5. Calcular o percentual de acerto da função.

A Figura 19 ilustra dois grupos,  $G_1$  e  $G_2$ , onde cada membro foi medido na escala de duas variáveis  $X_1$  e  $X_2$  e apresenta ainda um diagrama de dispersão, onde  $X_1$  e  $X_2$  são os dois eixos. O número 1 identifica as amostras do  $G_1$  e o número 2 identifica as amostras do  $G_2$ . As elipses resultantes abrangem uma quantidade específica de observações. Uma linha reta é traçada entre os dois grupos, e a partir daí é projetada para um novo eixo  $D$ . A sobreposição entre as distribuições de probabilidade univariadas  $G_1'$  e  $G_2'$  é representada pela área de interseção entre  $G_1'$  e  $G_2'$  (NARESH 2008).

**Figura 19 - Interpretação geométrica da análise discriminante**



**Fonte: Adaptado de Naresh (2008)**

O método consiste em obter funções matemáticas capazes de classificar um indivíduo  $X$  (uma observação  $X$ ) em uma de várias populações  $\pi_i$ , ( $i = 1, 2, \dots, n$ ), com base em medidas de um número  $p$  de características, buscando minimizar a probabilidade de má classificação, isto é, minimizar a probabilidade de classificar erroneamente um indivíduo em uma população  $\pi_i$ , quando realmente pertence a população  $\pi_j$ , sendo ( $i \neq j$ )  $i, j = 1, 2, \dots, n$  (NARESH, 2008).

A função discriminante linear de Fisher é uma combinação linear de características originais a qual se caracteriza por produzir separação máxima entre duas populações. Considerando que  $\mu_i$  e  $\Sigma$  são parâmetros conhecidos e respectivamente, os vetores de médias e a matriz de covariâncias comum das populações  $\pi_i$ . Demonstra-se que a função linear do vetor aleatório  $X$  que produz separação máxima entre duas populações é dada pela Equação (52) (NARESH, 2008).

$$D(x) = \hat{L}' \cdot X = [\mu_1 - \mu_2]' \cdot S_c^{-1} \cdot X, \quad (52)$$

e

$$S_c = \left[ \frac{n_1 - 1}{(n_1 - 1)(n_2 - 1)} \right] \cdot S_1 + \left[ \frac{n_2 - 1}{(n_1 - 1)(n_2 - 1)} \right] \cdot S_2, \quad (53)$$

em que,

$D(x)$  = função discriminante linear amostral de Fisher;

$\hat{L}'$  = estimativa do vetor discriminante;

$\mu_1$  = média amostral da população  $\pi_1$ ;

$\mu_2$  = média amostral da população  $\pi_2$ .

$S_c^{-1}$  = estimativa da matriz comum de covariâncias  $\Sigma$ ;

$n_1$  = número de observações da população  $\pi_1$ ;

$n_2$  = número de observações da população  $\pi_2$ ;

$S_1$  = estimativa matriz de covariâncias da população  $\pi_1$ ;

$S_2$  = estimativa matriz de covariâncias da população  $\pi_2$ .

Neste trabalho, o método Análise Discriminante foi usado no processo de agrupamento de uma das amostras de dados usados no predição de resistência dos concretos, conforme apresentado no capítulo 3 (item 3.3).

## 2.5 Ajuste de Hiperparâmetros

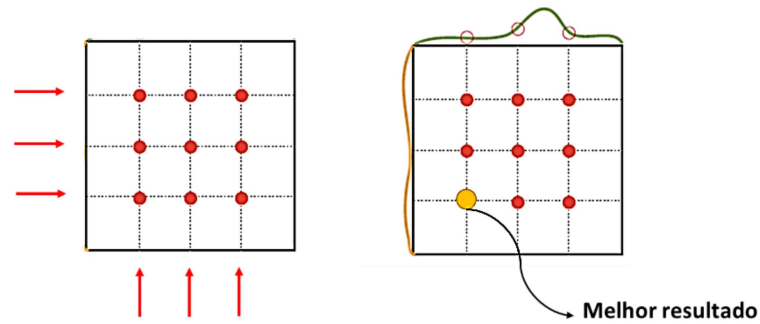
Grande parte dos algoritmos de ML possuem hiperparâmetros cujos valores devem ser especificados pelo usuário. Esses valores para os hiperparâmetros livres, geralmente influenciam diretamente no desempenho de modelos induzidos, o que pode ser entendido como uma deficiência das técnicas de ML, uma vez que afetam a velocidade e qualidade do processo de aprendizagem. O objetivo do processo de ajuste desses hiperparâmetros pode ser visto como encontrar os melhores valores dos parâmetros livres para um determinado conjunto de dados (HUTTER; HAMADI, 2005).

Frequentemente, existem heurísticas gerais ou regras básicas para configurar os hiperparâmetros, entretanto uma melhor abordagem é pesquisar objetivamente valores diferentes para os hiperparâmetros do modelo e escolher um subconjunto que resulte em um modelo que obtenha o melhor desempenho em um determinado conjunto de dados (otimização de hiperparâmetros).

Um procedimento de otimização envolve a definição de um espaço de busca, que representa geometricamente um volume  $n$ -dimensional (*search space*), em que cada hiperparâmetro representa uma dimensão diferente e a escala da dimensão são os valores que o hiperparâmetro pode assumir, como valor real, valor inteiro ou categórico. Um ponto no espaço de busca é um vetor com um valor específico para cada valor de hiperparâmetro. O objetivo do procedimento de otimização é encontrar um vetor que resulte no melhor desempenho do modelo após o aprendizado, com precisão máxima ou erro mínimo (ALVARENGA JÚNIOR, 2018).

Uma variedade de diferentes algoritmos de otimização de hiperparâmetros pode ser usada, entre as técnicas de ajuste de hiperparâmetros mais usadas tem-se o *grid search*. Esse método diz respeito à busca aleatória pelos melhores parâmetros como um *grid* de valores de hiperparâmetros e avalia cada posição no *grid*, através da análise dos resultados obtidos com a execução do algoritmo para um intervalo de parâmetros, conforme ilustrado na Figura 20.

Figura 20 – Ilustração do treinamento do algoritmo de ajuste de hiperparâmetro *grid search*



Fonte: Adaptado de Shahul (2021)

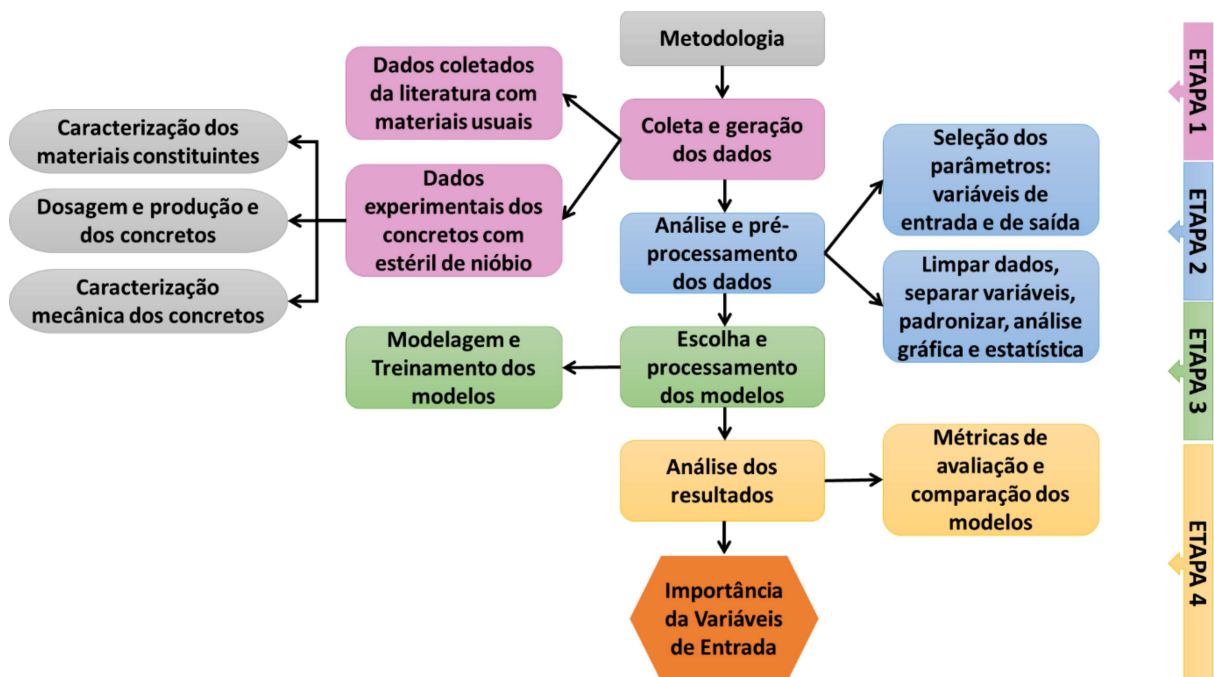
O *grid search* pode ser utilizado em conjunto com a validação cruzada, onde o conjunto de dados do domínio são particionados aleatoriamente em dois subconjuntos, um de teste e outro de treinamento. A validação cruzada diminui a probabilidade dos conjuntos de teste e treinamento serem particionados de forma inadequada, o que pode ocorrer caso essa divisão seja feita manualmente (HOANG; PHAM, 2016; KOYA *et al.*, 2021).

Neste trabalho foi utilizado o algoritmo de otimização de hiperparâmetros *grid search* com validação cruzada no treinamento dos algoritmos Árvore de Decisão, Floresta Aleatória, *Gradient Boosting* e *XGBoosting*.

### 3. MATERIAIS E MÉTODOS

Neste capítulo são apresentados os materiais e métodos empregados para o desenvolvimento deste estudo (Figura 21). A pesquisa foi composta por quatro etapas principais com dados estruturados. Na primeira delas, fez-se a coleta dos dados experimentais dos concretos produzidos com estéril de nióbio e de outros tipos de concretos convencionais presentes na literatura. Na segunda etapa, realizou-se o pré-processamento dos dados, analisando-os de acordo com sua recorrência (parâmetros de estudos) e interação entre eles (análise gráfica e estatística). A terceira etapa consistiu na programação e execução dos algoritmos de ML, com as configurações adotadas para os parâmetros dos modelos. A quarta etapa consistiu na análise dos resultados de acordo com as métricas adotadas e influência dos parâmetros selecionados para o estudo.

Figura 21 - Fluxograma explicativo da metodologia empregada na pesquisa



Fonte: Autora (2021)

### 3.1 Etapa 1 - Obtenção dos Dados

Neste estudo utilizou-se dois conjuntos de dados (*data sets*). O primeiro conjunto foi obtido experimentalmente com a moldagem e caracterização dos concretos com resíduo de nióbio (*data set 1*) e o segundo foi obtido através da compilação de dados experimentais da literatura em artigos, monografias, dissertações e teses de diferentes regiões do Brasil (*data set 2*).

- **Data set 1:** este conjunto de dados é composto por 128 amostras de concretos produzidos com estéril de nióbio, que foram moldados e caracterizados no LaMPPMin/UFCAT (LOPES, 2018). Os materiais constituintes dos concretos (água, cimento - CII Z 32, areia quartzosa e britas – gnaiss e estéril de nióbio) foram caracterizados de acordo com as normas brasileiras. Os concretos foram moldados pelo método da Associação Brasileira de Cimento *Portland* (ABCP) de acordo com a Associação Brasileira de Normas Técnicas (ABNT NBR 5738:2008), em corpos de prova cilíndricos de (10 x 20 cm), nas porcentagens de substituição de estéril de nióbio como agregado graúdo na mistura de (0; 25; 50; 75 e 100 %), adotando relação a/c de 0,5 e 0,7 e curados por imersão em água nas idades de (7, 14, 28 e 56 dias). Os concretos foram caracterizados no estado fresco (*slump test*) de modo a determinar sua trabalhabilidade, e no estado endurecido quanto a sua resistência mecânica à compressão axial ( $f_{ck}$ ) e à tração por compressão diametral ( $f_{ct}$ ) (Figura 22). Os ensaios de caracterização e moldagem dos concretos usados nesta pesquisa são apresentados na Tabela 3, juntamente com as normativas brasileiras que estabelecem os procedimentos experimentais dos concretos e seus materiais constituintes.

**Tabela 3 – Caracterização dos concretos produzidos com estéril de nióbio e seus materiais constituintes**


ENSAIOS DE CARACTERIZAÇÃO	NORMATIVAS
Dimensão máxima do Agregado Graúdo	ABNT NBR 7211:2009
Massa Específica do Agregado Graúdo	ABNT NBRNM 53:2009
Massa Específica do Agregado Miúdo	ABNT NBRNM52:2009
Massa Unitária	ABNT NBR NM 45:2006
<i>Slump test</i>	ABNT NBR NM 67:1998
Resistência à Compressão Axial	ABNT NBR 5739: 2007
Resistência Tração por Compressão Diametral	ABNT NBR 7222: 2010

**Fonte: Adaptado de Lopes (2018)**

Figura 22 – Caracterização mecânica dos corpos de provas dos concretos produzidos com estéril de nióbio



a) Compressão axial



b) Tração por compressão diametral

Fonte: Lopes (2018)

- **Data set 2:** este conjunto de dados é composto por 1517 amostras experimentais de concretos convencionais, compilados de 29 trabalhos acadêmicos usando técnicas semelhantes aos dos concretos produzidos com estéril de nióbio. Os dados foram selecionados considerando o uso de aditivos (%), relação a/c de 0,45 a 0,74, idades de cura de (3, 7, 14, 28 e 56 dias), traços dos concretos em proporção (1:areia: brita), e caracterização mecanicamente à compressão axial ( $f_{ck}$ ). A Tabela 4 apresenta os autores pesquisados e a quantidade de dados que compõem o *data set 2*.

Tabela 4 – Autores pesquisados e quantidade de dados que compõe o *Data Set 2*

AUTORES	REGIÃO	Nº DE AMOSTRAS
(ALHADAS, 2008)	MG	144
(ALVES, 2017)	RS	12
(ARAÚJO; GUIMARÃES; GEYER, 2016)	GO	96
(ARRUDA, 2013)	MG	60
(BARBOSA, 2009)	GO	44
(BECK, 2009)	RS	6
(EVANGELISTA, 2002)	RJ	75
(GORSKI, 2018)	SP	6
(GUIMARÃES, 2006)	MG	88
(KUMMER, 2016)	RS	30
(LOPES, 2018)	GO	32
(MARTINS, 2008)	GO	74
(MATTIA; VARGAS, 2017)	SC	40

(MEDEIROS JUNIOR <i>et al.</i> , 2014)	SP	48
(MELO NETO; HELENE, 2002)	SP	5
(NUNES, 2005)	RJ	144
(PACHECO, 2006)	ES	388
(REIS, 2004)	MG	24
(SAADE; SILVA; GOMES, 2009)	SP	10
(SAMPAIO; CARLOS, 2018)	MG	9
(SANTOS; GODINHO, 2017)	SC	30
(SIMÃO, 2014)	PE	27
(SOLLERO, 2019)	SP	17
(SOUZA, 2005)	SP	6
(SOUSA; OLIVEIRA; SOUZA, 2018)	PR	48
(TORALLES <i>et al.</i> , 2018)	PR	18
(VILELA, 2019)	GO	18
(ZANELLA, 2014)	RS	6
(ZANGESKI <i>et al.</i> , 2017)	MT	12
<b>Total de Amostras</b>		<b>1517</b>

Fonte: Autora (2021)

### 3.2 Etapa 2 – Seleção de Parâmetros, Análise e Pré-Processamento dos Dados

Nesta segunda etapa fez-se a organização dos dados em tabelas e a seleção dos parâmetros das variáveis de estudo para predição da resistência dos concretos de acordo com os trabalhos pesquisados na literatura no item 2.3. Os parâmetros escolhidos são de extrema importância, uma vez que influenciam na composição do concreto e conseqüentemente na sua resistência estrutural (BEHNOOD; GOLAFSHANI, 2020; CIHAN, 2019; DEROUSSEAU; KASPRZYK; SRUBAR, 2018; DUAN; KOU; POON, 2013; ERDAL; KARAKURT; NAMLI, 2013; HADZIMA-NYARKO *et al.*, 2020; JAIN; JHA; MISRA, 2008). Em seguida fez-se a separação dos dados categóricos (tipos de agregados e tipos de cimento) e numéricos (relação a/c, traço do concreto, idade e resistência mecânica).

Os parâmetros selecionados como variáveis de entrada foram:

- *Data set 1* – tipos de concreto (variando o % de substituição de estéril de nióbio), idade, cimento, areia, brita, água e *slump*;
- *Data set 2* – idade, areia, brita, relação a/c, uso de aditivo, tipos de agregados e tipos de cimentos.

Os parâmetros selecionados como variáveis de saída foram:

- *Data set 1* – resistência à compressão ( $f_{ck}$ ) e à tração ( $f_{ct}$ );
- *Data set 2* – resistência à compressão ( $f_{ck}$ ).

Todos estes parâmetros foram selecionados por estarem relacionados ao processo de dosagem dos concretos, de modo a atender os requisitos no estado fresco e endurecido, uma vez que estes parâmetros quando mal dosados ou misturados inadequadamente influenciam na variação da resistência mecânica (MA *et al.*, 2021; METHA; MONTEIRO, 2008; NGUYEN-SY *et al.*, 2020). A relação a/c foi escolhida porque é um parâmetro de dosagem que tem influência direta na resistência do concreto, no qual a quantidade de água é um fator importante para a estrutura da pasta de cimento hidratada e sua trabalhabilidade. O traço, que expressa a proporção entre os materiais usados na mistura, também tem influência marcante, na definição da estrutura de poros e na compacidade do material. Já a idade de ensaio é uma variável bastante importante nos concretos jovens, mas cuja importância relativa é reduzida, na medida em que avança o tempo de hidratação (NEVILLE, 2016).

Além de variações nesses parâmetros básicos, foi incluída a análise de concretos com agregados graúdos de diferentes mineralogias, com o intuito de verificar se as diferenças de compacidade, massa específica e afinidade química desses materiais com a matriz de cimento, que acarreta variações sensíveis nos resultados de resistência mecânica. Já o tipo de cimento foi selecionado devido a diferença presente em sua composição, cuja aplicação conforme apresentado na Tabela 1, tem influência na rapidez de hidratação, no comportamento dos concretos em relação à resistência mecânica (NEVILLE, 2016).

Do *data set 2* foram gerados 3 subconjuntos (grupos A, B e C), a partir do banco de dados de 1517 amostras, utilizando o método de Análise Discriminante. Os dados foram ordenados de forma crescente e divididos em intervalos de mesma amplitude ( $A$ ), calculado pela Equação (54).

$$A = \frac{h_s - h_i}{n} \quad (54)$$

onde  $A$  é a amplitude do intervalo de dados do grupos,  $n$  é o número de grupos adotado,  $h_i$  é o valor mínimo do intervalo de dados e  $h_s$  é o valor máximo do intervalo de dados.

A divisão dos intervalos foi feita tomando como referência os valores da relação a/c (0,45 a 0,74) dos concretos, que é o fator de grande influência na sua composição e possui uma relação inversamente proporcional à resistência mecânica dos concretos (METHA; MONTEIRO, 2008). O intuito da divisão do *data set 2* em subgrupos se deu com o objetivo de comparar os concretos produzidos com estéril de nióbio com outros tipos de concretos com diferentes tipos de agregados compilados da literatura, podendo assim verificar qual classe de agregados naturais ele se assemelha, conforme as características que apresentam em comuns e resistência mecânica (NEVILLE, 2016). Essa organização também é uma tentativa de avaliar as particularidades de desempenho dos algoritmos na predição de resistência de concretos em conjuntos de dados com alta variação de valores e com diferentes tipos de materiais, além da capacidade de generalização dos modelos.

Os dados foram analisados graficamente e estatisticamente usando os *softwares Excel Microsoft, Minitab Statistical, Past e Python®*. As análises foram feitas por meio de histogramas, boxplots, espaços de estado bidimensional das variáveis de entrada e saída, teste de normalidade, detecção de *outliers*, correlação e análise de variância (ANOVA). Os métodos foram utilizados para realizar a análise do comportamento das amostras, observações atípicas e valores discrepantes, dispersão dos dados, determinar a relação de causa e efeito entre as variáveis de entrada e saída, diferenças significativas entre as médias dos dados, e ainda, os fatores que exercem influência em alguma variável dependente.

Por fim, os dados foram transformados pelo método de *Box-Cox* usando o *software PAST®* (PINO, 2014; LOPES, 2012; YAN; SU, 2009). A transformação de *Box-Cox* é uma família de transformações de potência cujo objetivo é tornar os dados  $x_i$  mais similares a uma distribuição normal, expressa pela Equação (55):

$$y^\lambda = \begin{cases} \frac{x_i^{\lambda-1}}{\lambda}, & \text{para } \lambda \neq 0 \\ \ln(x_i), & \text{para } \lambda = 0 \end{cases}, \quad (55)$$

onde  $x_i$  é um valor de dados original,  $y^\lambda$  representa a observação transformada,  $\lambda$  é um parâmetro desconhecido para a transformação e  $\ln$  representa o logaritmo neperiano, proposta por *Box e Cox* (1964). O valor padrão do parâmetro  $\lambda$  é calculado maximizando a função de máxima verossimilhança (*lok likelihood function*), dada pela Equação (56):

$$L(\lambda) = -\frac{n}{2} \ln(\hat{\sigma}_\lambda^2) + (\lambda - 1) \cdot \sum_{i=1}^n x_i, \quad (56)$$

onde  $\hat{\sigma}_\lambda^2$  é a variância dos dados transformados.

### 3.3 Etapa 3 - Escolha e Processamento dos Modelos

Os modelos usados para a predição da resistência mecânica dos concretos produzidos com estéril de nióbio foram: Regressão Linear Múltipla, Regressão Polinomial (grau 2, 3 e 4), Regressão Mínimos Múltiplo Ordinários, Regressão Ridge, Regressão LASSO, Regressão Bayesiana, Redes Neurais Artificiais, Máquina de Vetores de Suporte, KNN, Árvore de Decisão, Floresta Aleatória, *Adaboost*, *Gradient Boosting* e *XGBoosting*. Como citado anteriormente, esses métodos foram selecionados com o intuito de investigar sobre o desempenho das técnicas de ML na predição de resistência dos concretos produzidos com estéril de nióbio e comparar quais métodos apresentam melhor precisão na predição.

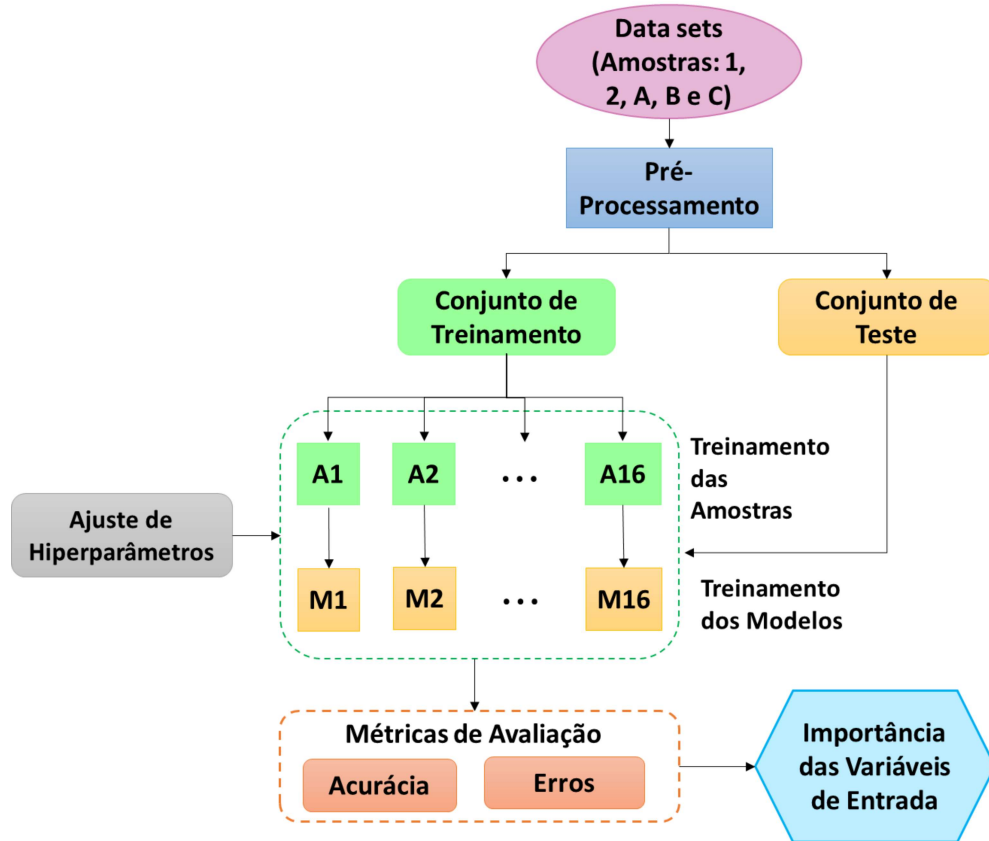
Para a simulação dos dados, os *data sets* foram particionados em um conjunto de treinamento e um conjunto de teste. A configuração adotada para os modelos foi de 70 % das amostras para treinamento e 30 % para teste, conforme proposto por Nguyen-Sy *et al.* (2020).

Para o algoritmo de redes neurais MLP a função de ativação adotada foi sigmóide tangente hiperbólica, a função de perda adotada foi gradiente descendente estocástico (SGD), variando de 1 a 3 camadas ocultas, 1000 épocas e até 200 neurônios por camadas, conforme proposto por Duan, Kou e Poon (2013) e Nguyen-Sy *et al.* (2020).

Utilizou-se também o algoritmo de ajuste de hiperparâmetro *grid search* nos modelos Árvore de Decisão, Floresta Aleatória, *Gradient Boosting* e *XGBoosting*, com o intuito de diminuir os erros e melhorar a acurácia dos modelos, conforme proposto por Hoang e Pham (2016) e Koya *et al.*, (2021).

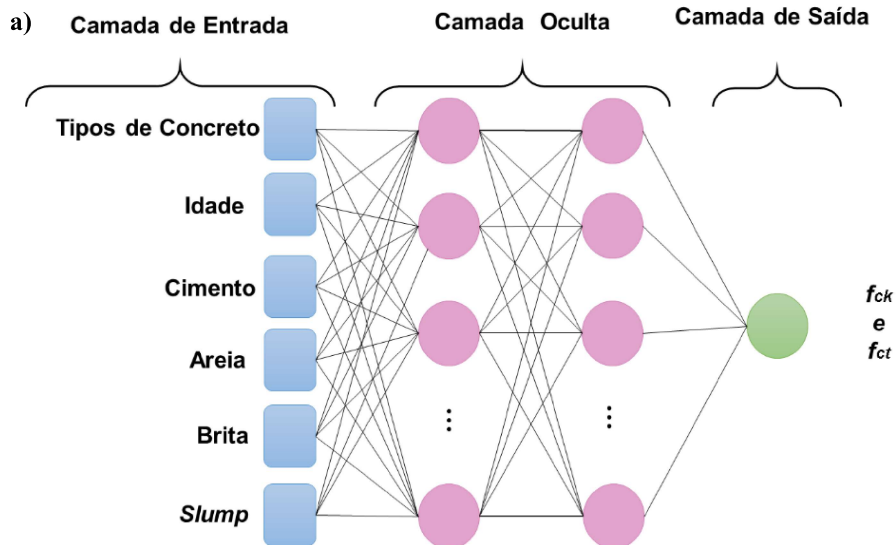
A Figura 23 apresenta um diagrama de fluxo do processo de previsão dos modelos e a Figura 24 apresenta as estruturas das RNAs usadas para a predição dos concretos.

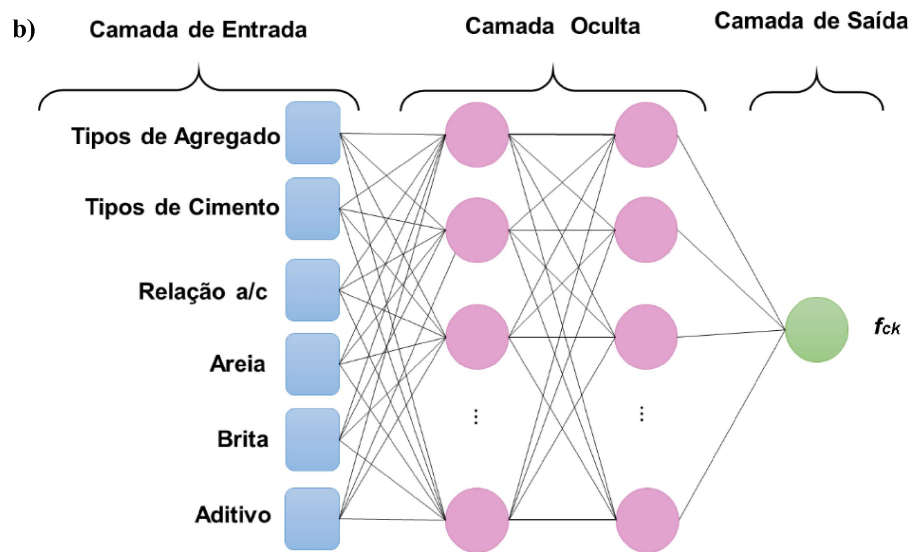
Figura 23 – Diagrama de treinamento dos modelos de ML para a resistência dos concretos



Fonte: Autora (2021)

Figura 24 – Estrutura das redes neurais artificiais treinadas: a) *Data Set 1* e b) *Data Set 2*





Fonte: Autora (2021)

Os modelos foram programados utilizando a linguagem *Python*® utilizando as seguintes bibliotecas:

- ***Pandas***: biblioteca para manipulação e análise de dados em tabelas numéricas e séries temporais;
- ***Numpy***: biblioteca para o processamento de vetores e matrizes, juntamente com uma grande coleção de funções matemáticas de alto nível para operar sobre as matrizes;
- ***Statsmodels***: biblioteca que permite aos usuários explorar dados, estimar modelos estatísticos e realizar testes estatísticos;
- ***Scipy***: biblioteca que fornece algoritmos para otimização, integração, interpolação, problemas de autovalor, equações algébricas, equações diferenciais, estatísticas e muitas outras classes de problemas matemáticos;
- ***Sklearn***: biblioteca que inclui vários algoritmos de classificação, regressão e agrupamento e é projetada para interagir com as bibliotecas *Python* numéricas e científicas *NumPy* e *SciPy*;
- ***Matplotlib e Seaborn***: bibliotecas de softwares para criação de gráficos e visualizações de dados em geral, feita para e da linguagem de programação *Python* e sua extensão de matemática *NumPy*;
- ***Shap***: biblioteca baseada em teorias de jogos para explicar a saída de predição de qualquer modelo de aprendizado de máquina.

### 3.4 Etapa 4 - Métricas de Avaliação

Nesta etapa para avaliar o desempenho de predição dos modelos escolhidos na simulação da resistência dos concretos, 4 diferentes parâmetros estatísticos foram empregados: raiz do erro médio quadrático (RMSE – *root mean square error*), erro médio quadrático (MSE – *mean square error*), erro médio absoluto (MAE – *mean absolute error*) e coeficiente de determinação ( $R^2$ ).

- RMSE: é uma medida que compara os valores observados com os respectivos valores preditos e calcula a média dos quadrados dos erros residuais. Desse modo, um baixo valor de RMSE indica um bom desempenho de predição do modelo. É calculado pela Equação (57):

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (y_i - \hat{y})^2} \quad (57)$$

- MAE: representa a diferença entre os valores originais e previstos extraído pela média da diferença absoluta sobre o conjunto de dados. É calculado pela Equação (58):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}| \quad (58)$$

- MSE: representa a diferença entre os valores originais e previstos extraídos pelo quadrado da diferença média sobre o conjunto de dados. É calculado pela Equação (59):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2 \quad (59)$$

- $R^2$ : representa o coeficiente de determinação, que mede a eficiência dos valores ajustados em comparação aos valores originais. O valor de  $R^2$  varia de 0 a 1, que significa a interpretação do modelo em porcentagem, e quanto maior for o valor, melhor é o modelo. O coeficiente  $R^2$  é calculado pela Equação (60):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (60)$$

onde,  $y_i$  é o valor predito de  $y$ ,  $\underline{y}$  é o valor médio de  $y$  e  $n$  é o número de amostras.

Além dos parâmetros de acurácia e erro, também utilizou-se a ferramenta SHAP (*SHapley Additive exPlanations*), que é um método usado com a finalidade de explicar previsões individuais das variáveis num modelo. Como os métodos usados em ML são do tipo “*black box*”, ou seja, exploram as relações entre os dados de entrada e saída sem fornecer uma estrutura viável do modelo (ZHANG *et al.*, 2021), o uso da ferramenta SHAP permite calcular a contribuição de cada variável do modelo para o resultado final da previsão, analisar a importância das variáveis para cada instância na base de dados e verificar se a influência da variável no resultado é positiva ou negativa (BEYER, 2021).

## 4. RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos a partir da execução das etapas propostas no capítulo 3. Primeiramente são analisados os resultados da caracterização dos materiais constituintes dos concretos e das resistências à compressão e à tração dos concretos produzidos com estéril de nióbio, comparando os valores medidos das propriedades dos concretos fabricados com diferentes percentuais de substituição do agregado gnaisse pelo estéril de nióbio. Em seguida é apresentada uma análise estatística dos *data sets* usados na predição dos concretos, que teve como objetivo verificar a distribuição dos dados, detecção de dados discrepantes e a relação dos dados de entrada com a variável de saída. Por fim são apresentados e discutido os resultados dos modelos treinados, comparando os melhores resultados para acurácia e menor erro dos *data sets* treinados.

### 4.1 Caracterização dos componentes do concreto

Os resultados da caracterização dos materiais constituintes do concreto são apresentados na Tabela 5.

**Tabela 5 - Parâmetros selecionados como variáveis de predição dos concretos**

MATERIAIS	AREIA	GNAISSE	ESTÉRIL DE NIÓBIO
Descrição	Fina	Brita 1	Brita 1
Massa específica (g/cm <sup>3</sup> )	2,65	2,69	2,73
Dimensão máxima (mm)	2,36	19,00	19,00
Módulo de finura	1,98	6,97	7,02
Massa unitária (kg/m <sup>3</sup> )	-	1396,47	1437,64

Fonte: Adaptado de Lopes (2018)

De acordo com os resultados de massa unitária do gnaisse e do estéril, é possível afirmar que os materiais analisados podem ser comumente usados para fabricação de concreto, como cita Metha e Monteiro (2008), uma vez que os agregados que possuem massa unitária entre 1300 kg/m<sup>3</sup> a 1750 kg/m<sup>3</sup> são usados para fabricação de concreto de peso normal.

## 4.2 Traço e dosagem do concreto.

Para a realização da dosagem do concreto foram adotadas as resistências características de 10 MPa e desvio padrão de  $D_p = 4,0$  MPa para os concretos com relação a/c de 0,7 e 20 MPa e desvio padrão de  $D_p = 4,0$  MPa para os concretos com relação a/c de 0,5, conforme determinado pela ABNT NBR 12655:2015 (HELENE; TUTIKIAN, 2011). O abatimento do tronco de cone (*slump test*) adotado foi de  $80 \pm 20$  mm. Os traços obtidos através dos cálculos propostos pela ABCP, são expressos na Tabela 6.

**Tabela 6 - Valores dos traços e do consumo de componentes**

COMPONENTES	CONSUMO	CONSUMO
Cimento CP II Z 32	370 kg/m <sup>3</sup>	440 kg/m <sup>3</sup>
Agregado Miúdo	810 kg/m <sup>3</sup>	689 kg/m <sup>3</sup>
Agregado Graúdo	1070 kg/m <sup>3</sup>	1098 kg/m <sup>3</sup>
Água	245 L/m <sup>3</sup>	225 L/m <sup>3</sup>
Traços	1 : 2,2 : 2,9 : 0,7	1 : 1,6 : 2,5 : 0,5

Fonte: Adaptado de Lopes (2018)

## 4.3 Concreto no estado fresco

Os dados de consistência do concreto no estado fresco (*slump test*) com (0, 25, 50, 75 e 100%) de substituição de estéril de nióbio, correspondem a 3 (três) medidas diferentes coletadas, e são apresentados na Tabela 7 juntamente com os valores da umidade relativa do ar e temperatura do laboratório durante a moldagem.

**Tabela 7 - Abatimento do tronco de cone, umidade relativa do ar e temperatura ambiente**

DOSAGEM	SLUMP TEST (mm)		UMIDADE RELATIVA DO AR (%)		TEMPERATURA (°C)	
Relação a/c	0,5	0,7	0,5	0,7	0,5	0,7
0 %	7,5	7,2	44	52	29,4	31,5
25 %	7,8	-	55	-	28,2	-
50 %	8,7	7,8	66	78	27,1	26,6
75 %	9,1	-	56	-	30,1	-
100 %	8,6	6,9	53	62	27,9	29,6

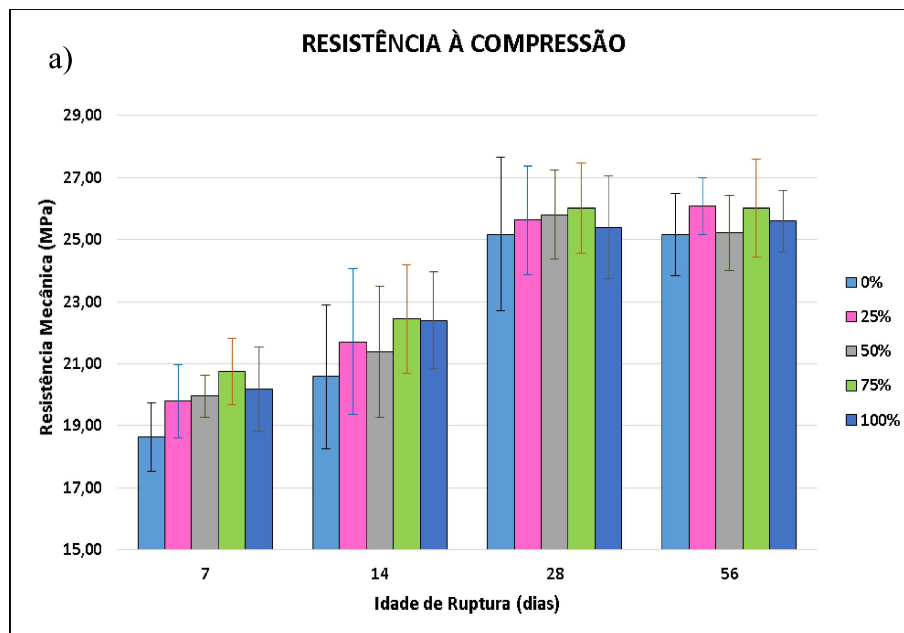
Fonte: Adaptado de Lopes (2018)

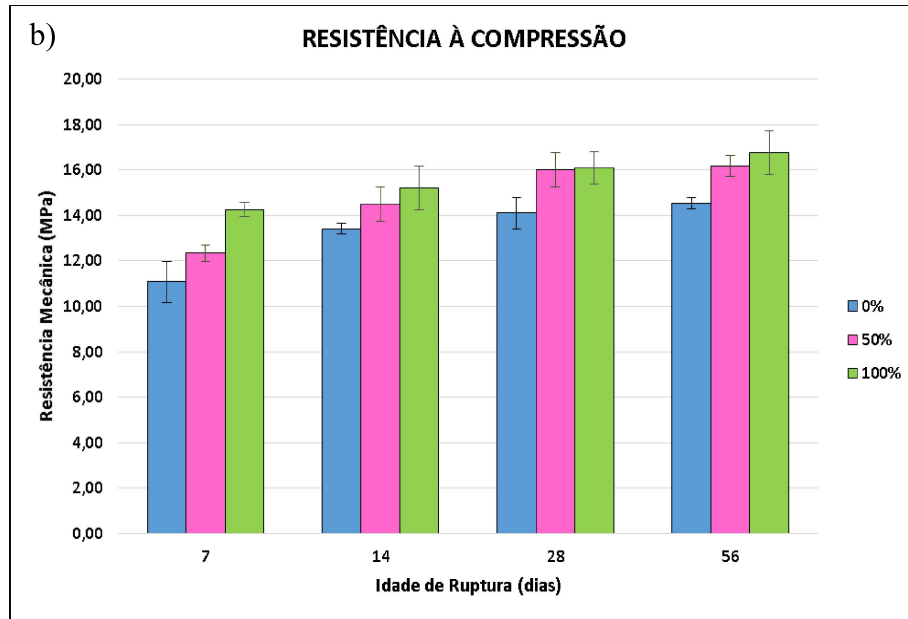
Nota-se que houve variação do abatimento dos concretos tanto com a variação do percentual de substituição de estéril de nióbio, quanto com os valores de relação a/c de 0,5 e 0,7. Fazendo uma análise comparativa entre os concretos que possuem a mesma relação a/c de 0,5 e 0,7, os resultados das aferições do abatimento dos concretos corresponderam ao esperado, estando dentro dos limites previstos e apresentando condições trabaláveis facilitando a moldagem (GUIMARÃES, 2006; NUNES, 2005; PACHECO, 2006).

#### 4.4 Resistência Mecânica dos Concreto no Estado Endurecido

Na Figura 25 são apresentados os resultados médios dos ensaios para determinação da resistência à compressão ( $f_{ck}$ ) e na Figura 26 os resultados médios dos ensaios para determinação da resistência à tração ( $f_{ct}$ ) dos concretos produzidos com estéril de nióbio. Os resultados também são apresentados nas tabelas do Apêndice (A).

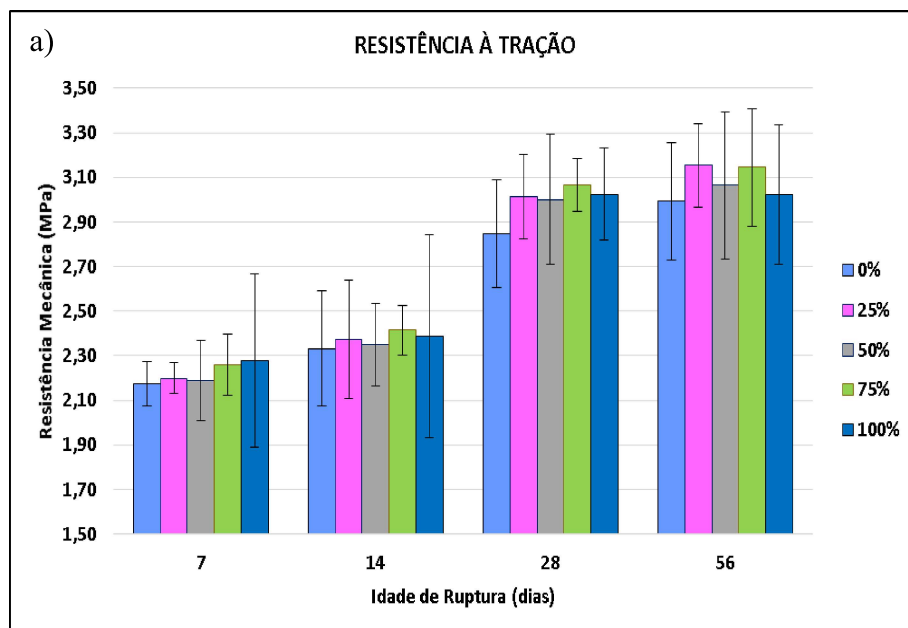
Figura 25 - Resultados médios do ensaio de resistência à  $f_{ck}$ . a) Relação a/c de 0,5; b) Relação a/c 0,7






Fonte: Autora (2021)

Figura 26 - Resultados médios do ensaio de resistência à  $f_{ct}$ ; a) Relação a/c de 0,5; b) Relação a/c 0,7





Fonte: Autora (2021)

Nota-se que há o aumento das resistências em relação às idades de maturação dos concretos, tanto para o ensaio de compressão quanto de tração. Em relação às porcentagens de substituição do agregado graúdo de gnaiss por estéril de nióbio, têm-se que os concretos com maior resistência foram o de 75 % e de 100 % de estéril de nióbio, para ambos os ensaios de resistência mecânica.

Analisando os concretos produzidos com 0 % e 100 % de substituição do agregado gnaiss pelo estéril de nióbio, percebe-se que as resistências obtidas com 100% de estéril de nióbio estão bastante próximas ou superiores ao concreto com gnaiss, entre 90 % a 110 % de ganho de resistência. O que indica que este material é compatível com o agregado gnaiss quanto à sua resistência mecânica, podendo assim ser aplicado como agregados em concretos.

#### 4.5 Análise Gráfica e Estatística dos Dados

A Tabela 8 apresenta os valores resumidos dos *data sets* com as informações dos parâmetros selecionados para o estudo da predição dos concretos produzidos com estéril de nióbio. Os dados completos são apresentados no Apêndice (D).

Tabela 8 - Parâmetros selecionados como variáveis de predição dos concretos

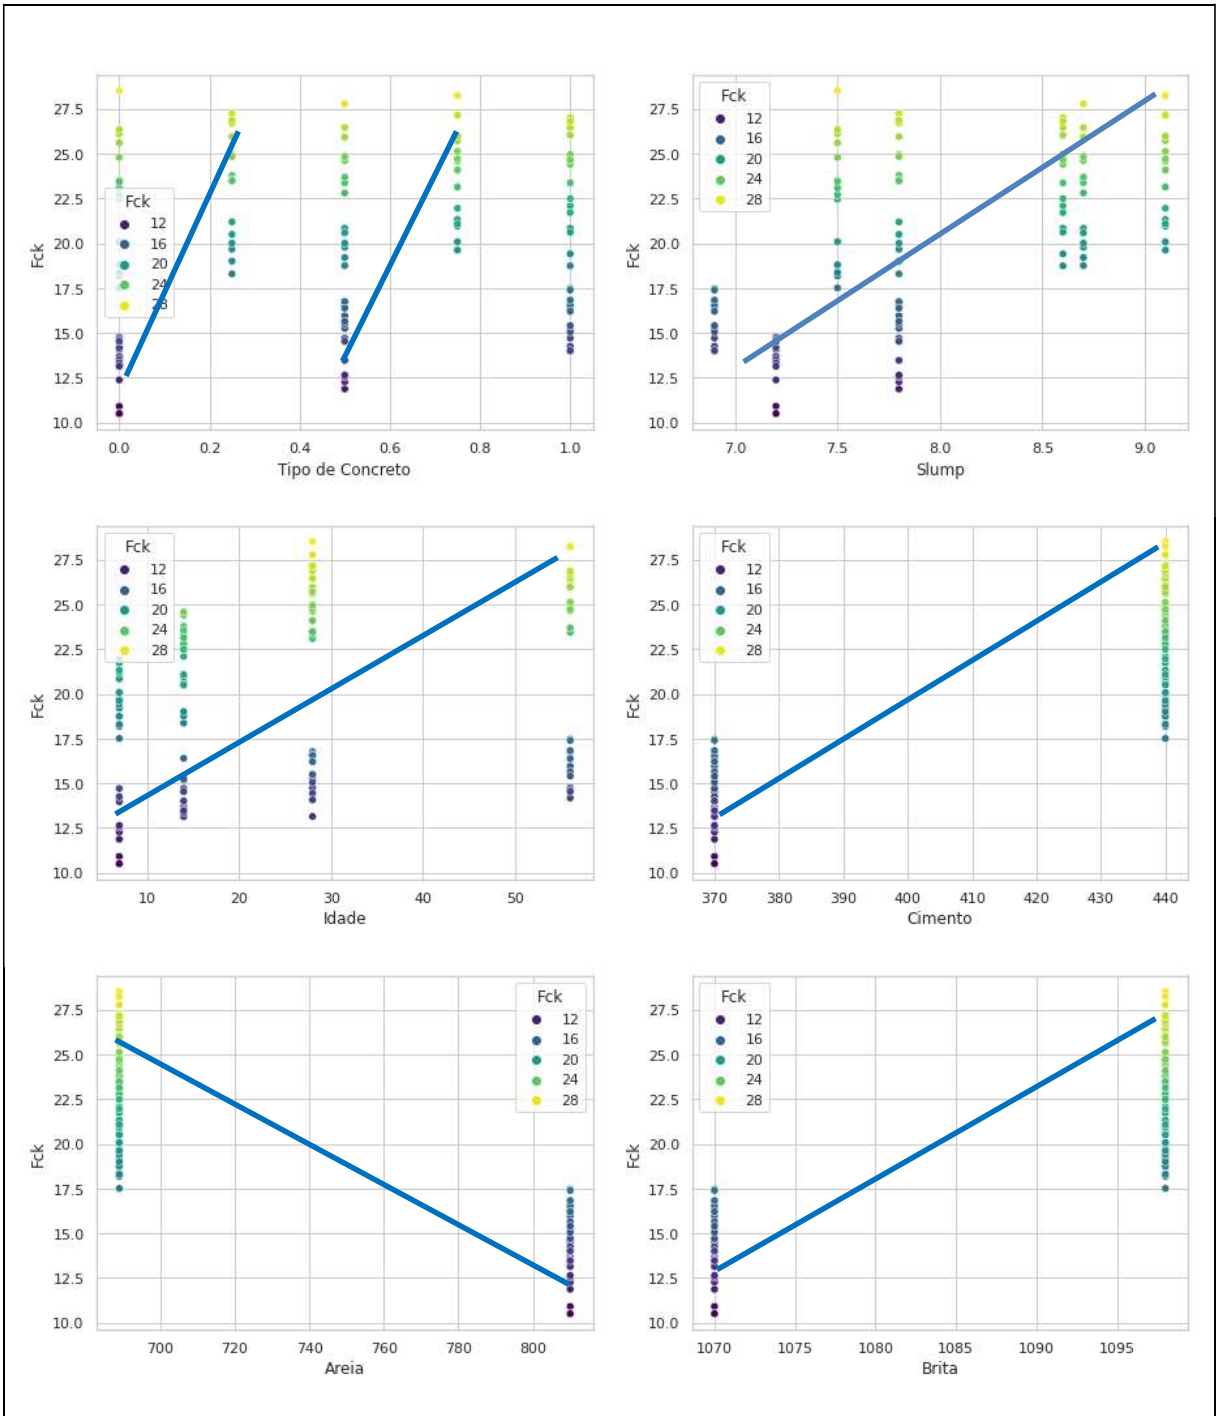
VARIÁVEIS NUMÉRICAS					
VARIÁVEIS	UNIDADE	MÍNIMO	MÁXIMO	MÉDIA	DESVIO PADRÃO
<b>DATA SET 1</b>					
Tipo de Concreto	%	0,00	100,00	50,00	37,73
Idade	dias	7,00	56,00	26,25	18,73
Cimento	kg / m <sup>3</sup>	370,00	440,00	413,75	34,08
Areia	kg / m <sup>3</sup>	689,00	810,00	734,38	58,90
Brita	kg / m <sup>3</sup>	1070,00	1098,00	1087,50	37,65
Água	L / m <sup>3</sup>	225,00	245,00	232,50	9,74
Slump	cm	6,90	9,10	7,95	0,72
f <sub>ck</sub>	MPa	10,50	28,51	19,95	4,91
f <sub>ct</sub>	MPa	1,16	3,42	2,30	0,61
<b>DATA SET 2</b>					
Idade	dias	3,00	56,00	21,76	14,90
Areia	1:areia	0,92	4,01	2,27	0,64
Brita	1:brita	1,50	4,86	3,11	0,64
Relação a/c	1:água	0,45	0,74	0,57	0,07
Aditivo	%	0,00	0,03	0,01	0,01
f <sub>ck</sub>	MPa	3,59	65,40	28,20	9,82
<b>VARIÁVEIS CATEGÓRICAS</b>					
Tipos de Agregados	basalto, calcário, diabásio, dolomito, estéril de nióbio, ganisse, granito, granulito, micaxisto, quartzo, seixo lavado, seixo misto, seixo rolado, sienito, traquito				
Tipos de Cimentos	CP I S 32; CP II E 32; CP II F 32, CP II F 40; CP II Z 32; CP III 32; CP III RS 40; CP IV; CP V ARI				

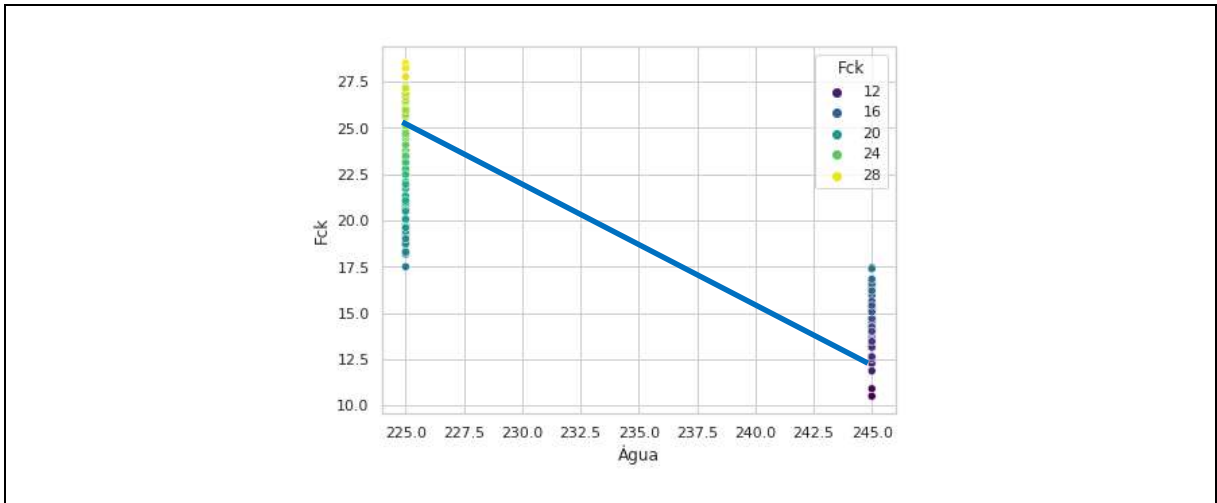
Fonte: Autora (2021)

#### 4.5.1 Análise do *Data Set 1*

As Figuras 27 e 28 apresentam os gráficos de dispersão de cada parâmetro do *data set 1* em relação às resistências mecânicas de compressão (f<sub>ck</sub>) e tração (f<sub>ct</sub>).

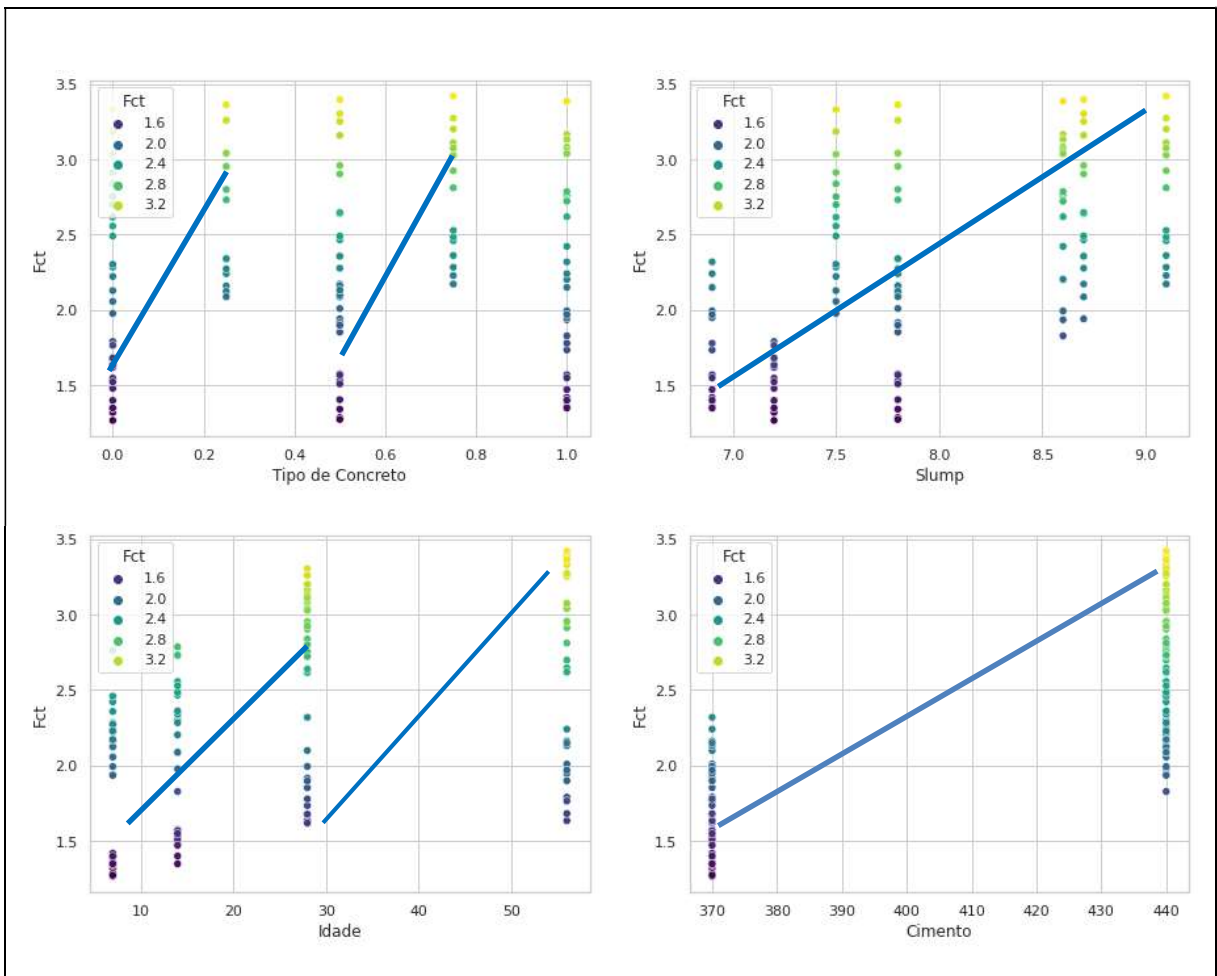
Figura 27 - Gráficos de dispersão dos parâmetros do *Data Set 1* versus a resistência à compressão ( $f_{ck}$ ) dos concretos produzidos

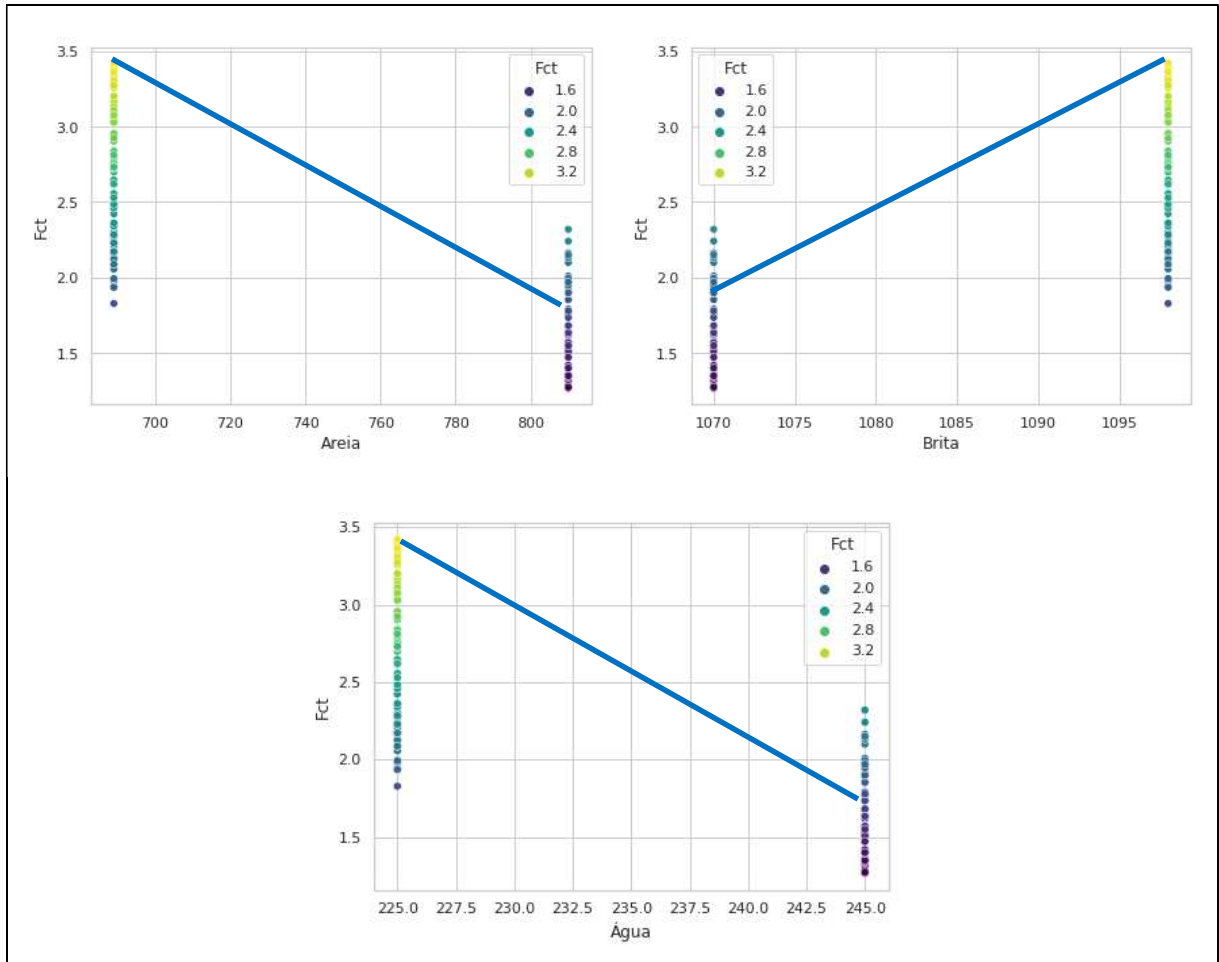




Fonte: Autora (2021)

Figura 28 – Gráficos de dispersão dos parâmetros do *Data Set 1* versus a resistência à tração ( $f_{ct}$ ) dos concretos produzidos



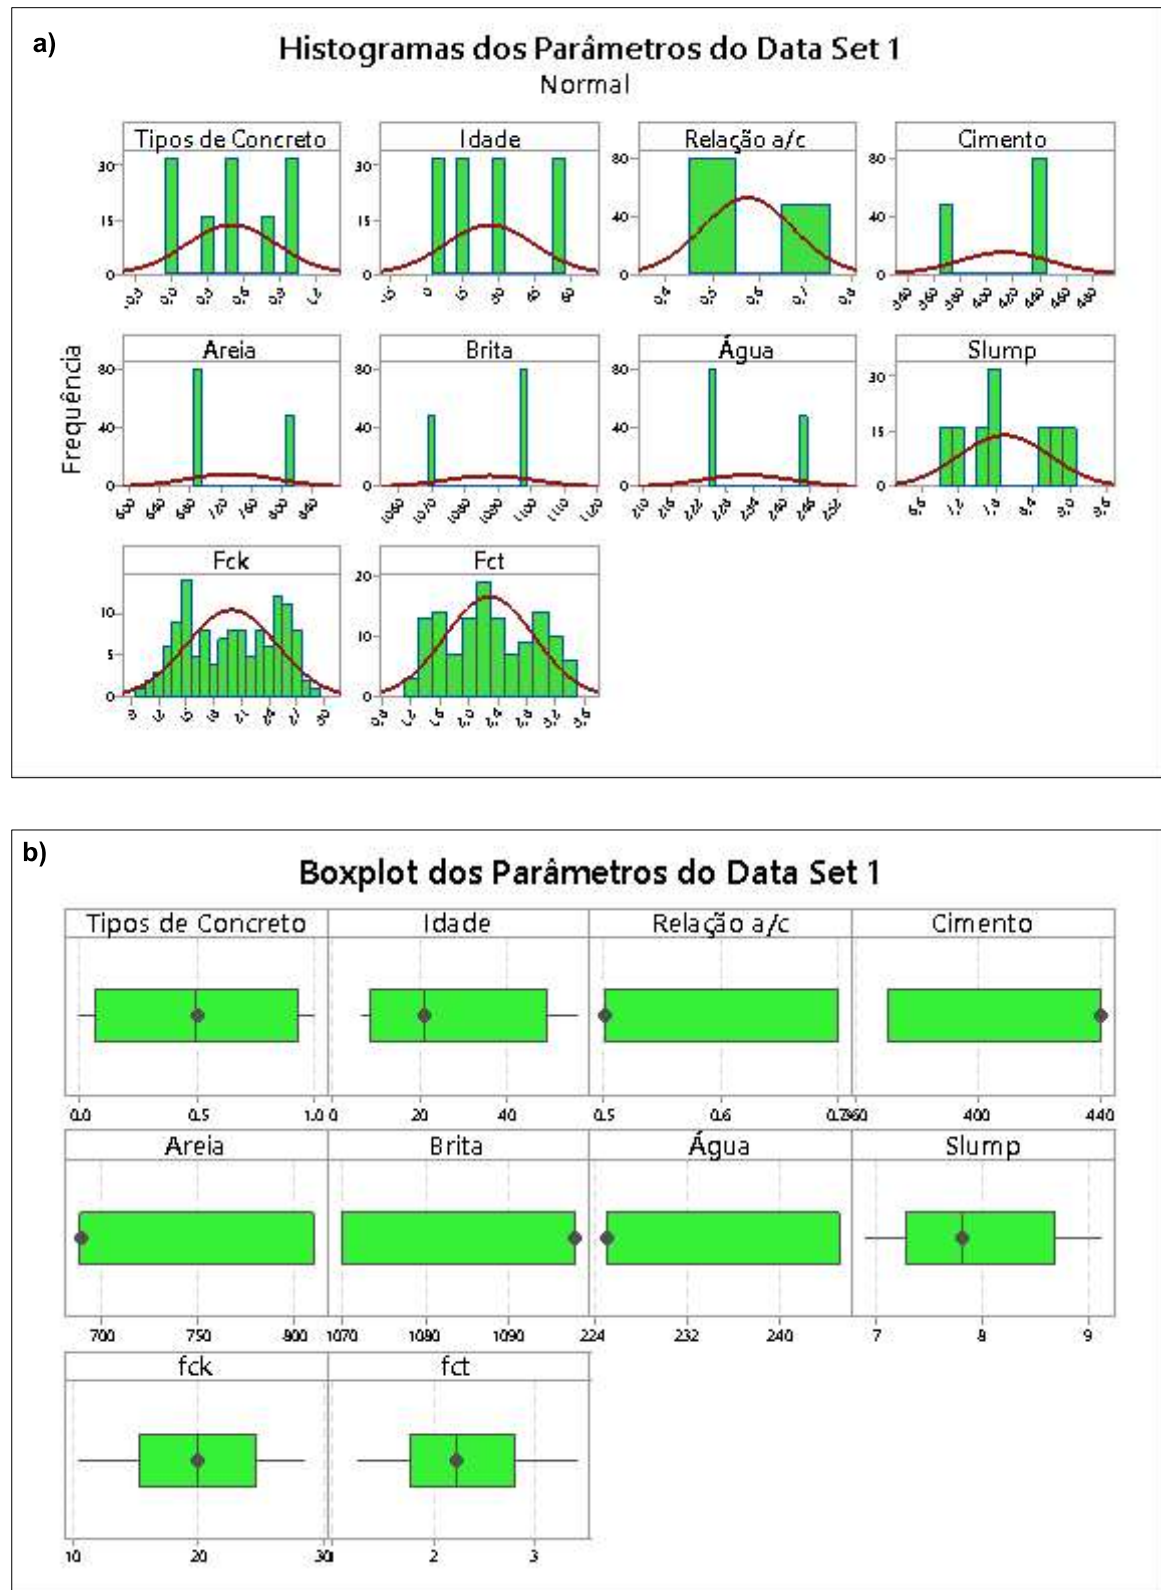


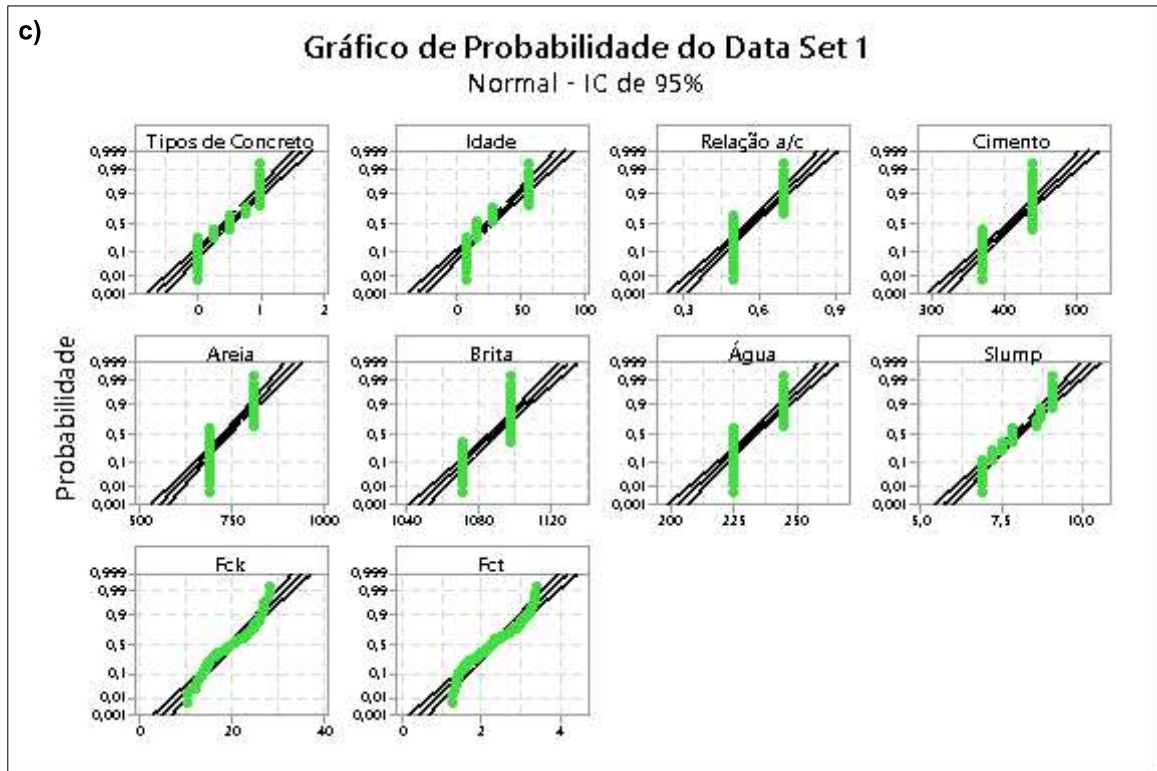
Fonte: Autora (2021)

Analisando os resultados apresentados nas Figuras 27 e 28 nota-se que as variáveis idade, cimento, brita e *slump* apresentam relação positiva e não linear em relação às resistências mecânicas. As outras variáveis se encontram dispersas de forma estratificada, e portanto não é possível determinar uma relação direta com as resistências mecânicas. Esse tipo de comportamento dos dados é caracterizado como dados multimodais, que tem mais de um pico de ocorrência, e geralmente acontece quando os dados são coletados a partir de mais de um processo ou condição de medição. O fato das amostras se apresentarem de forma estratificadas nesse estudo é devido aos procedimentos de medição das resistências dos concretos, nos quais foram realizados em diferentes idades e relação a/c, evidenciando diferentes agrupamentos das amostras.

A Figura 29 apresenta os gráficos de histogramas, boxplots e de probabilidades de cada parâmetro do *data set* 1.

Figura 29 – Gráficos de a) Histogramas, b) Boxplots e c) Probabilidade do *Data Set 1*





Fonte: Autora (2021)

Através dos resultados apresentados nos histogramas das variáveis do *data set 1*, tem-se que não é possível concluir que os dados seguem uma distribuição normal. Assim como nos gráficos de dispersão, os histogramas apresentam mais de um pico de frequência, onde cada pico representa um tipo de ajuste dos dados, com distribuição multimodal. Quanto às simetrias das frequências dos histogramas, percebe-se para as variáveis relação a/c, areia e água têm assimetria à esquerda, o que pode indicar que a variação das quantidades desses materiais usados na mistura dos concretos estudados influenciam no aumento das resistências mecânicas. Estes resultados podem ser melhor compreendidos conforme é explicado na literatura (METHA; MONTEIRO, 2008; PACHECO, 2006), onde a água é um importante componente do concreto, uma vez que tem as funções de provocar a reação de hidratação dos compostos do cimento e aumentar a trabalhabilidade para que possa preencher adequadamente as fôrmas, sem causar vazios ou nichos. Quando dosada em quantidade acima da prevista na mistura do concreto, aumenta a porosidade, e conseqüentemente, diminui a resistência, ampliando o risco de patologias. Já a areia por ser um material inerte, que não reage quimicamente com o cimento e a água, diminui a reação química entre o cimento e a água, ajudando a evitar a perda de umidade, o surgimento das trincas e rachaduras no concreto após o seu endurecimento.

Por outro lado, analisando as frequências das variáveis cimento e brita, que têm assimetria à direita, percebe-se que os concretos que a variação nas quantidades desses materiais na mistura dos concretos como estéril de nióbio, também pode influenciar no aumento da resistência mecânica. Estes resultados podem ser melhor compreendidos conforme é explicado por Neville (2016), onde a relação agregado/cimento, embora seja considerado como um fator secundário na resistência dos concretos, o ganho de resistência e paralelamente a redução de cimento em concretos é influenciado por fatores que ocorrem na dosagem, produção e interação entre os materiais como: a redução do relação água/cimento, escolha correta de agregados, máximo preenchimento do volume do concreto pelos agregados, procedimento e eficiência da mistura e os tipos de cimentos a serem empregados.

Quanto à dispersão nos gráficos de boxplot dos valores tem-se que as variáveis: tipo de concreto, resistências  $f_{ck}$  e  $f_{ct}$  apresentam distribuições proporcionais à sua mediana, ou seja, metade dos dados estão localizados entre o 1º e 3º quartil da linha central da caixa. Esses resultados revelam que a maioria dos valores das resistências estão concentradas entre 15 e 25 MPa para  $f_{ck}$  e 1,5 e 2,5 MPa para  $f_{ct}$ . Já as variáveis cimento, areia, água e brita apresentam assimetrias e uma distribuição mais afastada da mediana, evidenciando que esses dados apresentam alta variação entre seus valores extremos (limite superior e limite inferior) e podem não ser normalmente distribuídos.

Em relação à curtose apresentadas nos histogramas, que significa o grau de achatamento de uma distribuição em relação à distribuição normal, nota-se que as variáveis que mais se aproximam de uma distribuição normal são as resistências  $f_{ck}$  e  $f_{ct}$ , enquanto que o restante das variáveis apresentam um achatamento das curvas de distribuição, evidenciando a dispersão dos valores da sua medida central, ou seja, não estão normalmente distribuídos.

Em relação à distribuição dos dados nos histogramas, boxplots e os gráficos de probabilidade percebe-se que não há presença de valores discrepantes (*outlier*). Nos gráficos de probabilidade nota-se ainda que os valores das amostras apresentam um crescimento na mesma direção, entretanto não com uma taxa constante. Esse tipo de comportamento caracteriza uma relação monotônica não linear dos dados, o que indica uma forte correlação entre as variáveis e comportamento não linear.

Na Tabela 9 estão expressos os valores da análise de variância (ANOVA) para as resistências à compressão ( $f_{ck}$ ) e à tração ( $f_{ct}$ ), em relação às variáveis adotadas como parâmetros de entrada no *data set* 1. De acordo com Kitchenham *et al.* (2017) é importante

avaliar a significância das variáveis escolhidas como parâmetros de estudo e como elas se correlacionam, de modo a ajudar a compreender os modelos estatísticos que melhor se adequam à predição da resistência dos concretos.

**Tabela 9 – ANOVA dos parâmetros do Data Set 1**

ANÁLISE DE VARIÂNCIA - $f_{ck}$							
FATOR	GL	VALOR F	VALOR-P	S	R <sup>2</sup>	R <sup>2</sup> (PRED)	ERRO
Tipos de Concreto	4	7,5	0,00	447,264	19,61%	13,74%	123
Idade	3	8,51	0,00	452,441	17,07%	11,63%	124
Cimento	1	346,39	0,00	254,544	73,33%	72,57%	126
Areia	1	346,39	0,00	254,544	73,33%	72,57%	126
Brita	1	346,39	0,00	254,544	73,33%	72,57%	126
Água	1	346,39	0,00	254,544	73,33%	72,57%	126
Slump	6	25,93	0,00	332,646	56,26%	52,05%	121
Todos*	8	33871,66	0,00	242,107	99,58%	99,57%	1143
ANÁLISE DE VARIÂNCIA - $f_{ct}$							
FATOR	GL	VALOR F	VALOR-p	S	R <sup>2</sup>	R <sup>2</sup> (PRED)	ERRO
Tipos de Concreto	4	5,7	0,00	0,579996	15,64%	9,25%	123
Idade	3	15,77	0,00	0,535066	27,62%	22,87%	124
Cimento	1	199,04	0,00	0,388452	61,24%	60,11%	126
Areia	1	199,04	0,00	0,388452	61,24%	60,11%	126
Brita	1	199,04	0,00	0,388452	61,24%	60,11%	126
Água	1	199,04	0,00	0,388452	61,24%	60,11%	126
Slump	6	17,85	0,00	0,463698	46,96%	41,42%	121
Todos*	8	34284,43	0,00	241,562	99,58%	99,58%	1143


\* Análise de variância com todos os parâmetros; GL – graus de liberdade; S – desvio padrão da distância entre os valores dos dados e os valores ajustados; R<sup>2</sup> - representa a porcentagem de variação na resposta que é explicada pelo modelo; R<sup>2</sup>(PRED) determinar o quão bem seu modelo prediz as respostas para novas observações; Valor F - compara a quantidade de variância sistemática nos dados com a quantidade de variância não-sistemática; O valor-p é uma probabilidade que mede a evidência contra a hipótese nula. As probabilidades inferiores fornecem evidências mais fortes contra a hipótese nula. Fonte: Autora (2021)


De acordo com a ANOVA, considerando como hipótese nula ( $H_0$ ) que afirma que as médias do grupo são todas iguais e ( $H_1$ ) que afirma que nem todas as médias do grupo são iguais, num intervalo de confiança de 95 % e valor de p igual a 5 % de nível de significância, as variáveis que têm o maior percentual de representação da resistência dos concretos são: cimento, areia, brita e água, ou seja, os materiais constituintes do concreto. Conforme apontado por diversos autores na literatura, esses parâmetros são essenciais como variáveis de entrada para a simulação dos modelos de ML no estudo da resistência mecânica dos concretos. Do

mesmo modo, observa-se que quando analisadas todas as variáveis em conjunto, estas apresentam diferenças significativas de 99,58 %, o que indica que essas variáveis têm uma forte correlação entre si (BEN CHAABENE; FLAH; NEHDI, 2020; DUAN *et al.*, 2021; HUANG *et al.*, 2020; JAIN; JHA; MISRA, 2008).

A Figura 30 apresenta os gráficos de correlação de Pearson que mede o grau de relação linear entre cada par de variáveis dos parâmetros do *data set 1*. Os valores de correlação variam entre -1 e +1, e os sinais positivo e negativo indicam a direção ao que as variáveis estão relacionadas, ou seja, diretamente ou inversamente proporcionais. A magnitude de força de correlação entre as variáveis é classificada entre os intervalos como: 0,10 até 0,39 fraca, de 0,40 até 0,69 moderada, de 0,70 até 1 forte (FILHO; JÚNIOR, 2009).

**Figura 30 - Correlação de Pearson dos parâmetros do *Data Set 1*: a) Resistência à compressão ( $f_{ck}$ ) e b) Resistência à tração ( $f_{ct}$ )**






No correlograma da resistência à tração ( $f_{ct}$ ) as variáveis cimento, brita e *slump* apresentam uma forte correlação negativa, ou seja, estão inversamente relacionadas. Já as variáveis areia e água apresentam uma forte correlação positiva com o  $f_{ct}$ , o que indica que a maior a quantidade desses materiais na dosagem do concreto, têm maior influência nos mecanismos de falha e fissuração do material na tensão nominal. Conforme já mencionado, a quantidade de água na mistura do concreto influencia na sua porosidade e trabalhabilidade. Concretos mal adensados no processo de moldagem podem ocasionar um mal empacotamento dos grãos, gerando vazios na pasta de cimento e má aderência da pasta de cimento aos agregados. Este processo de segregação dos materiais juntamente com os vazios presentes no compósito de concreto, quando submetidos a um carregamento de força elevará as concentrações de tensões do material, causando microfissuras nos cristais do cimento hidratado. Embora essa tensão seja relativamente baixa, quando comparada com a resistência à


compressão axial, a ruptura microscópica no local de uma falha irá se propagar por toda a seção do corpo de prova sob uma determinada tensão, e conseqüentemente na ruptura macroscópica do material (NEVILLE, 2016).

Analisando o correlograma da resistência à compressão ( $f_{ck}$ ) as variáveis água e areia apresentam uma forte relação inversamente proporcional, o que indica que os concretos dosados com menor quantidade desses materiais na composição dos concretos, têm maior influência no aumento da sua resistência mecânica. Por outro lado, a forte correlação positiva das variáveis cimento e brita indica que o maior dimensionamento desses materiais, principalmente do agregado graúdo no concreto, pode proporcionar ganho de resistência nos concretos produzidos com estéril de nióbio (METHA; MONTEIRO, 2008).

Já a variável idade apresenta uma relação positiva com ambas resistências,  $f_{ck}$  e  $f_{ct}$ , o que corrobora com os dados experimentais que o ganho de resistência do concreto se dá com a maturação das idades do concreto, conforme apresentado na Figura 31.

**Figura 31 – Gráfico de intervalos da resistências mecânicas versus as idades do concreto com estéril de nióbio do *Data Set 1***





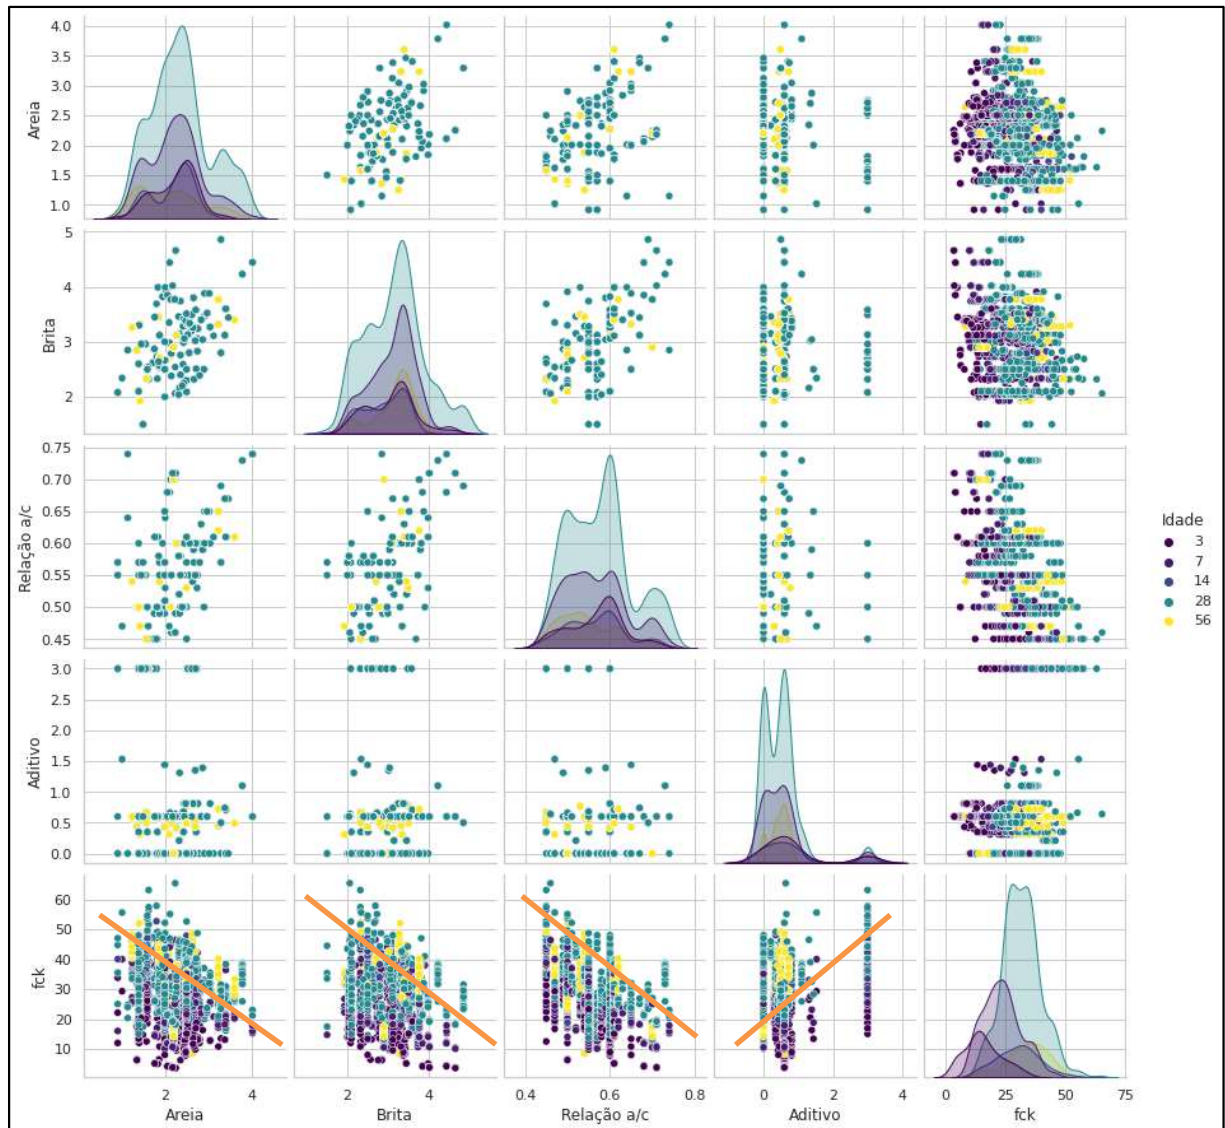
Fonte: Autora (2021)

#### 4.5.2 Análise do *Data Set 2*

A Figura 32 apresenta os gráficos de dispersão de cada parâmetro do *data set 2* em relação à resistência à compressão ( $f_{ck}$ ) dos dados obtidos da literatura.

Os resultados mostram que a variável relação a/c e resistência  $f_{ck}$  apresenta uma relação negativa, não linear e inversamente proporcional, ou seja, quanto maior a quantidade de água na mistura, menores os valores de resistência dos concretos. As variáveis areia e brita não apresentam relação com a resistência  $f_{ck}$ , já as variáveis idade e aditivo apresentam uma dispersão estratificada das amostras. Conforme citado anteriormente, o comportamento das amostras estratificadas é devido ao processo de medição dos corpos de prova dos concretos, que ocorrem em diferentes idades e relação a/c. Já a estratificação da variável aditivo é devido à diversificação das misturas de concretos compilados na literatura, cujo o uso de aditivo é indicado para melhorar a plasticidade dos concretos, retardar ou acelerar o endurecimento dos concretos, proporcionar uma maior variedade de componentes na mistura, e ainda a reduzir a quantidade de água. Nota-se que quanto maior o percentual em massa de aditivo nos concretos, maiores os valores de resistência à compressão.

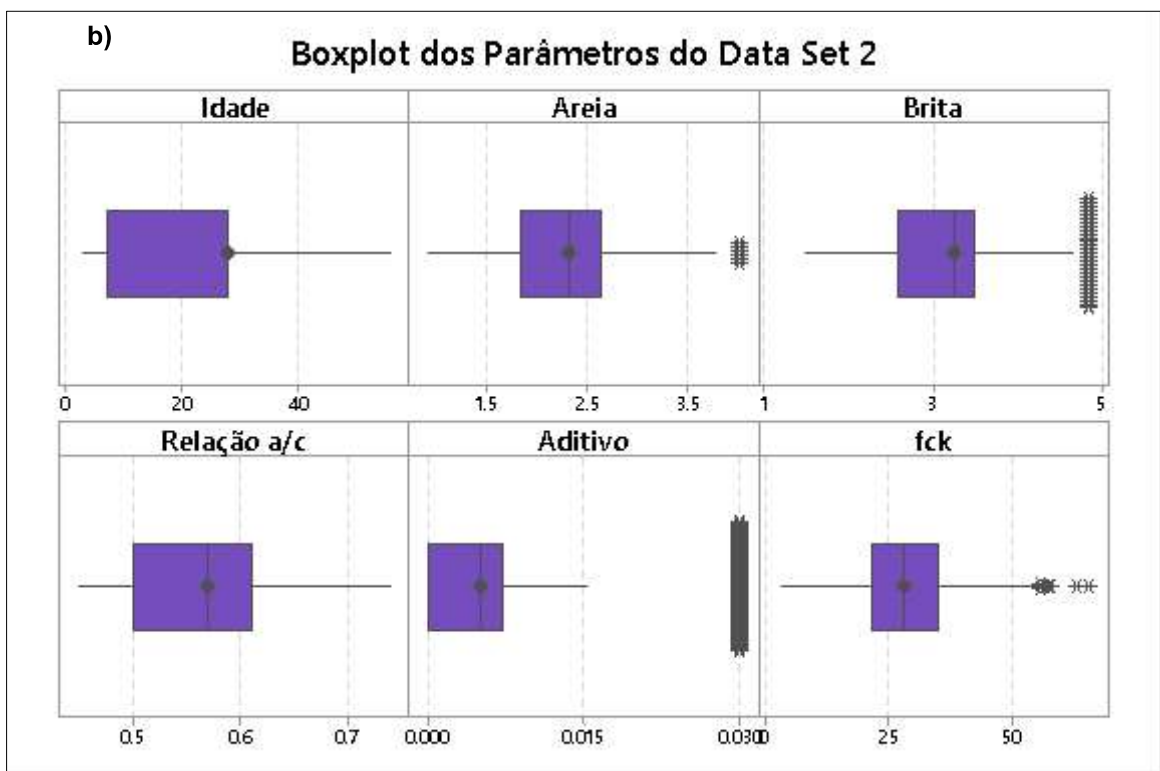
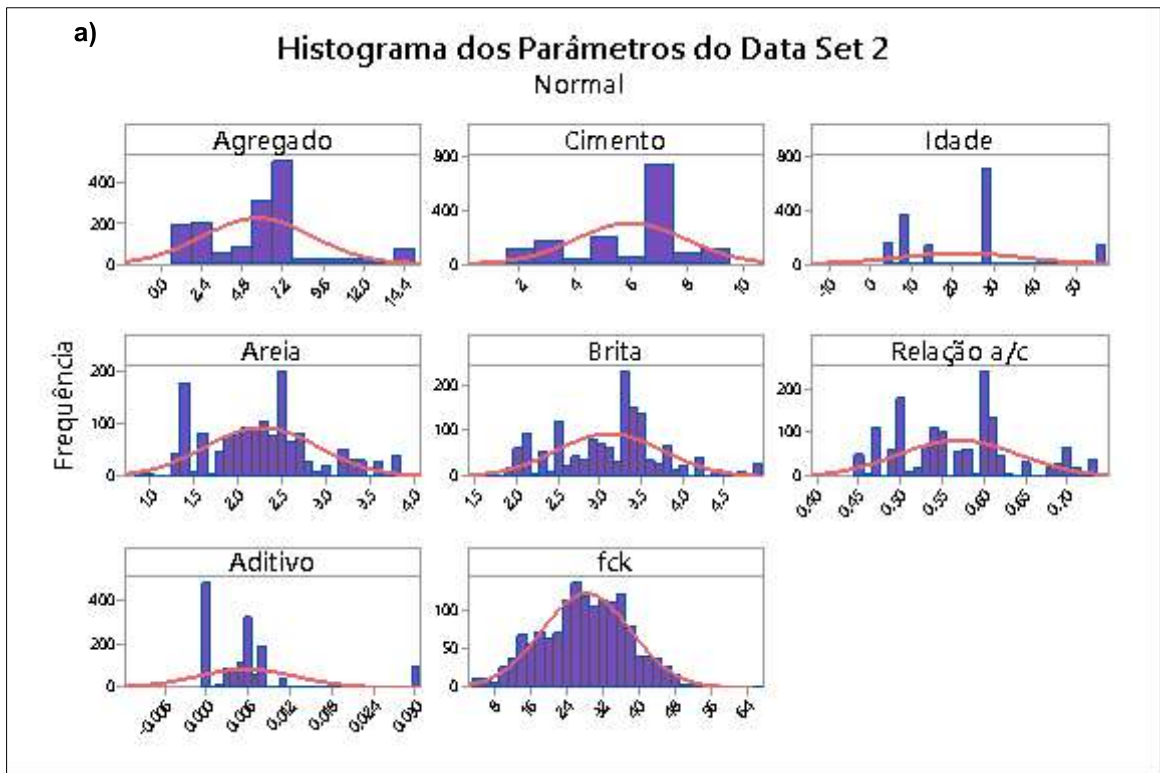
Figura 32 – Gráficos de dispersão dos parâmetros do *Data Set 2* versus a resistência à compressão ( $f_{ck}$ ) dos concretos compilados da literatura

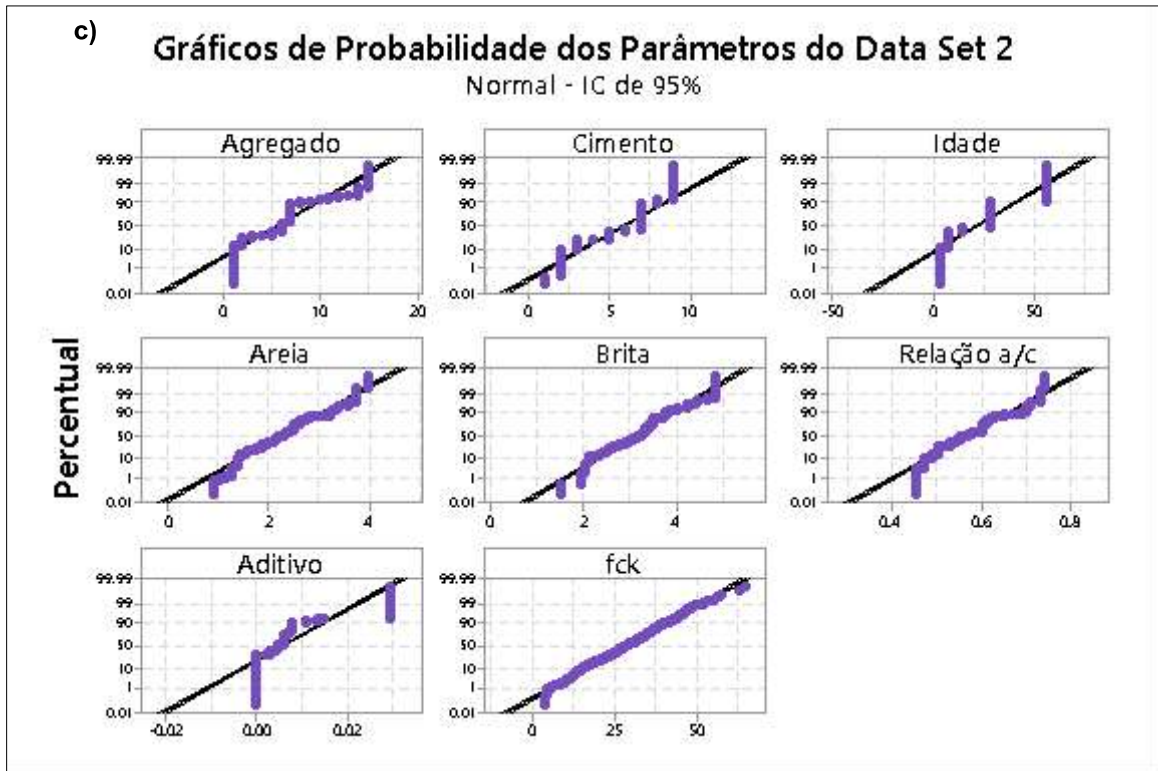


Fonte: Autora (2021)

A Figura 33 apresenta os gráficos de histogramas, boxplots e de probabilidades de cada parâmetro do *data set 2*.

Figura 33 – Gráficos: a) Histogramas, b) Boxplots e c) Probabilidade do *Data Set 2*





Fonte: Autora (2021)

Analisando os resultados apresentados nos histogramas dos parâmetros do *data set 2*, nota-se que apenas a variável de resistência  $f_{ck}$  apresenta uma distribuição normal. Este resultado é evidenciado também no gráfico de probabilidade, onde os dados mostram um crescimento linear e constante. As variáveis idade e aditivos mostram um grande achatamento na curva de normalidade, o que indica que estes dados apresentam uma grande variação entre as amostras. Já as variáveis areia, brita e relação a/c apresentam diferentes picos na sua distribuição e achatamento da curva de normalidade. Esses comportamentos indicam que não é possível afirmar que estas variáveis possuem comportamento normal, além disso, percebe-se uma grande quantidade de dados atípicos (*outlier*) presentes nas extremidades superior e inferior destes dados para a maioria dos gráficos analisados.

Em relação às simetrias das frequências dos histogramas e boxplots, percebe-se para as variáveis: tipos de agregado, tipos de cimento, idade e aditivos apresentam uma grande dispersão dos dados em relação às suas medianas. Esses resultados também evidenciam que os tipos e quantidades adotadas desses materiais nos concretos estão relacionadas com a resistência mecânica dos concretos ao longo do tempo (CASTRO, 2017; MEDEIROS-JUNIOR, 2015; NUNES, 2005; PACHECO *et al.*, 2019; SANTOS *et al.*, 2017).

Na Tabela 10 estão expressos os valores da análise de variância (ANOVA) para a resistência à compressão ( $f_{ck}$ ) do *data set 2*.

**Tabela 10 – ANOVA dos parâmetros do *Data Set 2***

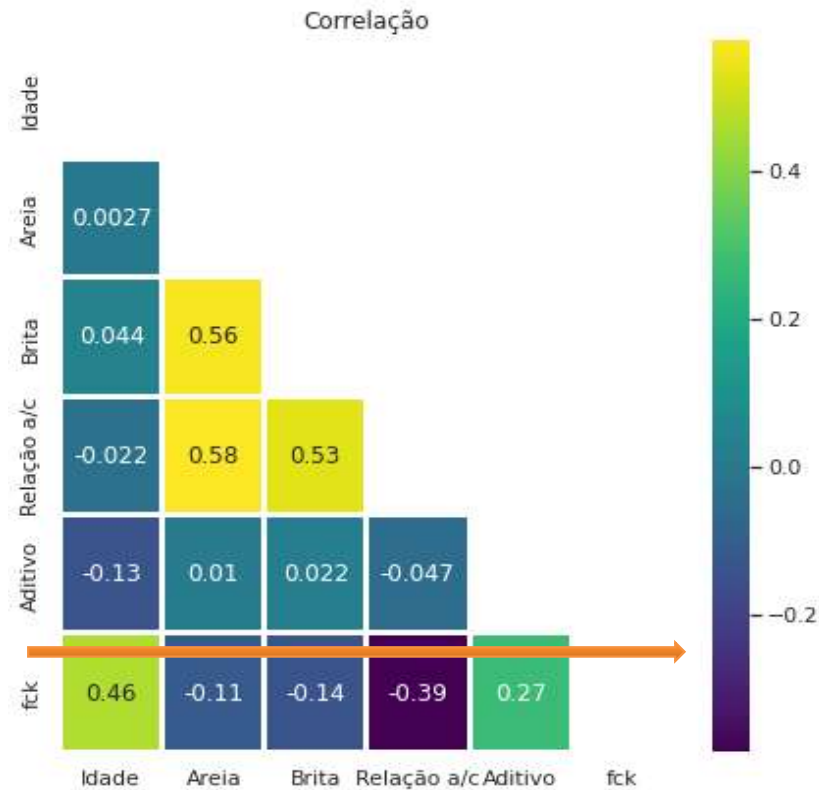
ANÁLISE DE VARIÂNCIA								
FONTE	GL	VALOR F	VALOR P	S	R <sup>2</sup>	R <sup>2</sup> (AJ)	R <sup>2</sup> (PRED)	ERRO
Agregado	14	31,02	0	869,209	22,43%	21,71%	21,26%	1502
Cimento	8	35,94	0	902,646	16,01%	15,57%	15,11%	1508
Idade	4	172,12	0	815,374	31,29%	31,11%	30,82%	1512
Areia	87	11,85	0	771,231	41,90%	38,36%	40,24%	1429
Brita	87	10,06	0	796,869	37,97%	34,20%	36,81%	1429
Relação a/c	25	34,42	0	788,770	36,59%	35,53%	34,78%	1491
Aditivo	31	11,93	0	888,111	19,94%	18,27%	16,06%	1485
Todos*	5	4347,68	0	729,654	70,50%	70,48%	70,46%	9096

\* Análise de variância com todos os parâmetros. Fonte: Autora (2021)

De acordo com a ANOVA, considerando como hipótese nula ( $H_0$ ) que afirma que as médias do grupo são todas iguais e ( $H_1$ ) que afirma que nem todas as médias do grupo são iguais, num intervalo de confiança de 95 % e valor de p igual a 5 % de nível de significância, as variáveis que têm o maior percentual de representação da resistência dos concretos são: idade, areia, brita e relação a/c. Conforme já citado, esses parâmetros são essenciais como variáveis de entrada para a simulação dos modelos de ML no estudo da resistência mecânica dos concretos. Da mesma forma ao *data set 1*, observa-se que quando analisadas todas as variáveis em conjunto, estas apresentam diferenças significativas de 70,50 %, o que indica que essas variáveis têm uma forte correlação entre si e são significativas para descrever os modelos estatísticos (MONTGOMERY; RUNGER, 2014; TEIXEIRA *et al.*, 2015).

A Figura 34 apresenta o gráfico de correlação de Pearson reduzido, que mede o grau de relação linear entre cada par de variáveis dos parâmetros do *data set 2*. O correlograma completo com todas as variáveis analisadas é apresentado no Apêndice B.

Figura 34 – Correlação de Pearson dos Parâmetros do *Data Set 2*



Fonte: Autora (2021)

O correlograma da resistência à compressão ( $f_{ck}$ ) em relação às variáveis predictoras aponta que as variáveis areia, brita e relação a/c apresentam uma fraca relação inversamente proporcional, o que indica que os concretos com menores quantidades desses materiais na sua composição, apresentaram um aumento na resistência mecânica. Por outro lado, as variáveis idade e aditivo têm uma fraca correlação positiva, indicando que os concretos analisados com maior quantidade desses materiais, principalmente do agregado graúdo, proporcionaram maior ganho de resistência à compressão.

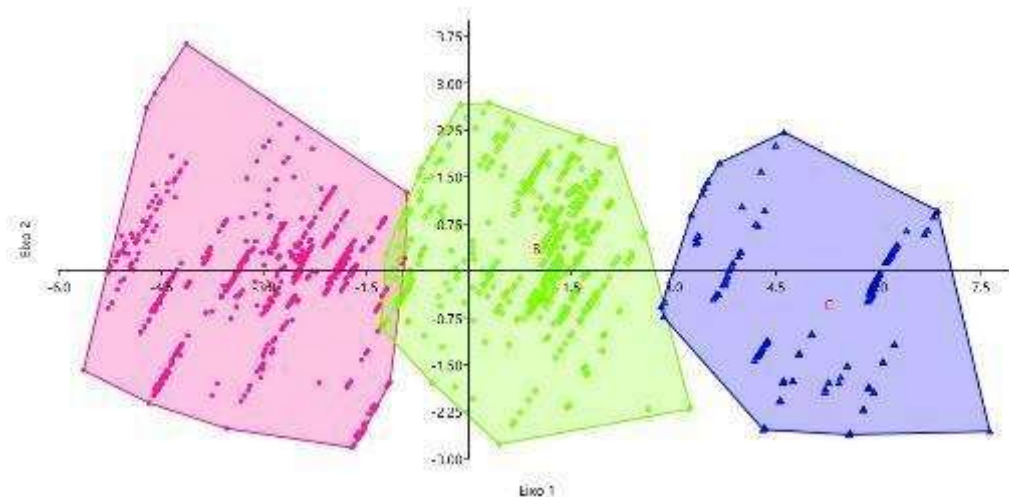
Na Figura B1 presente no Apêndice B, é possível verificar quais tipos de agregados e cimentos também apresentam correlação com a resistência  $f_{ck}$  dos concretos. Os agregados granito, sienito e o cimento CP III RS 40, apresentam uma fraca correlação positiva com o  $f_{ck}$ . Já os agregados calcário, estéril de nióbio, seixo lavado, seixo rolado e cimento CP II Z 32, apresentam uma fraca correlação negativa com a resistência  $f_{ck}$ . Esses resultados podem estar associados à heterogeneidade dos dados compilados, que possui uma grande variação de valores dos parâmetros de entrada analisados e tipos de materiais, bem como às características físicas e químicas desses materiais, e sua interação na mistura do concreto. Outros fatores como erros

experimentais inerentes ao processo de produção e caracterização dos concretos podem também ser apontados como causadores da fraca correlação com a resistência dos concretos presentes nesse *data set*.

#### 4.6 Agrupamento dos Dados do *Data Set 2*

O *data set 2* foi dividido em três subconjunto de dados através do método de análise discriminante, tomando como referência a relação a/c dos concretos que variaram de 0,45 a 0,74. O agrupamento teve como finalidade verificar se os tipos de agregados presentes nessa base de dados apresentam características significativas com o material estéril de nióbio, assim como de analisar sobre a capacidade de generalização e predição dos algoritmos de ML para a predição da resistência desses concretos. A Figura 35 ilustra o agrupamento das amostras nos grupos A, B e C. A Tabela 11 apresenta o resumo da organização da divisão do *data set 2* nos três grupos (A, B e C) usados nesta pesquisa.

Figura 35 – Agrupamento do *Data Set 2* nos grupos A, B e C



Fonte: Autora (2021)

Tabela 11 – Dados dos conjuntos A, B e C

GRUPO S	RELAÇÃO A/C	Nº DE AMOSTRAS
A	0,45 - 0,54	697
B	0,55 - 0,64	726
C	0,65 - 0,74	271

Fonte: Autora (2021)

Após a análise estatística dos conjuntos de dados, fez-se a exclusão dos valores discrepantes (*outlier*), e em seguida a transformação das amostras pelo método de *Box-Cox* para serem simulados nos modelos de ML (JAMES *et al.*, 2013; KITCHENHAM *et al.*, 2017).

#### 4.7 Análise da Predição da Resistência dos Concretos

A seguir são apresentados os resultados da predição da resistência à compressão dos concretos dos *data sets* 1 e 2 e dos conjuntos A, B e C, com as métricas de acurácia ( $R^2$ ), os erros calculados: médio quadráticos (MSE), erro médio absoluto (MAE) e raiz do erro médio quadrático (RMSE), e as variáveis que apresentaram maior influência na predição dos concretos.

##### 4.7.1 Algoritmos de Aprendizagem Aplicados ao *Data Set* 1

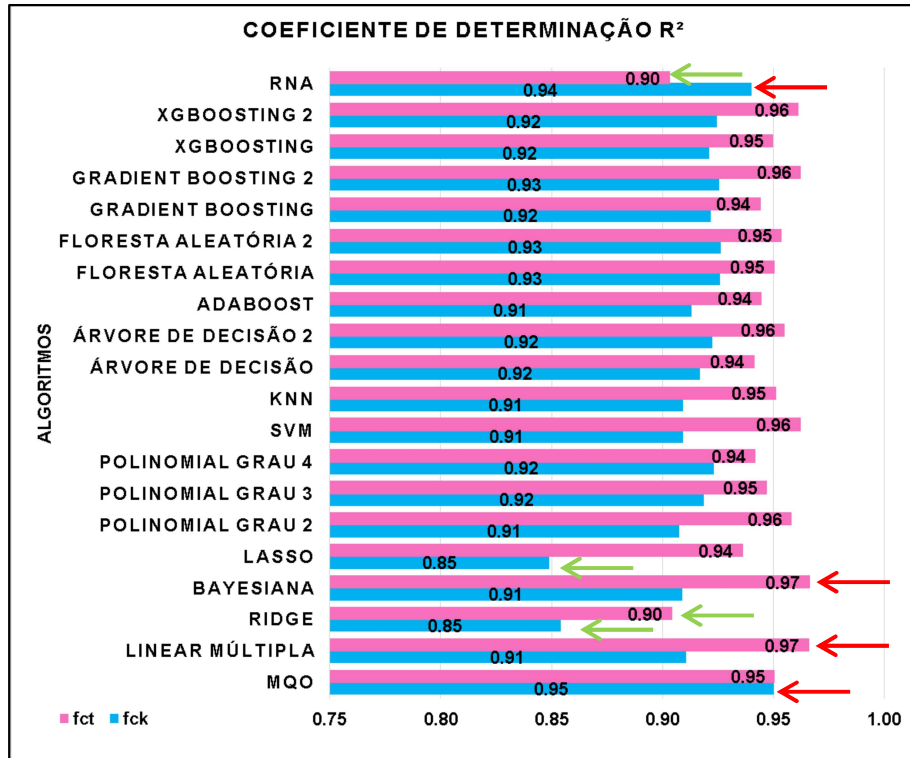
Os resultados obtidos para a predição dos concretos quanto sua resistência à compressão ( $f_{ck}$ ) e à tração ( $f_{ct}$ ) são apresentados a seguir. Na Tabela 12 estão expressos os valores máximos e mínimos obtidos na simulação do *data set* 1. A Figura 36 mostra os valores do coeficiente de determinação  $R^2$  e a Figura 37 os valores obtidos para os erros de cada modelo.

Tabela 12 – Resultados da predição dos concretos para o *Data Set* 1

RESISTÊNCIAS	VALORES	TREINO $R^2$	TESTE $R^2$	MSE	MAE	RMSE
$f_{ck}$	Max	0,97	0,95	3,10	1,39	1,76
	Min	0,85	0,85	0,01	0,06	0,08
$f_{ct}$	Max	0,96	0,97	0,55	0,54	0,74
	Min	0,85	0,90	0,01	0,07	0,08


Fonte: Autora (2021)


Figura 36 – Coeficiente de determinação  $R^2$  dos modelos na predição das resistências  $f_{ck}$  e  $f_{ct}$



Fonte: Autora (2021)

Figura 37 – Erros RMSE, MAE e MSE dos modelos na predição das resistências  $f_{ck}$  e  $f_{ct}$





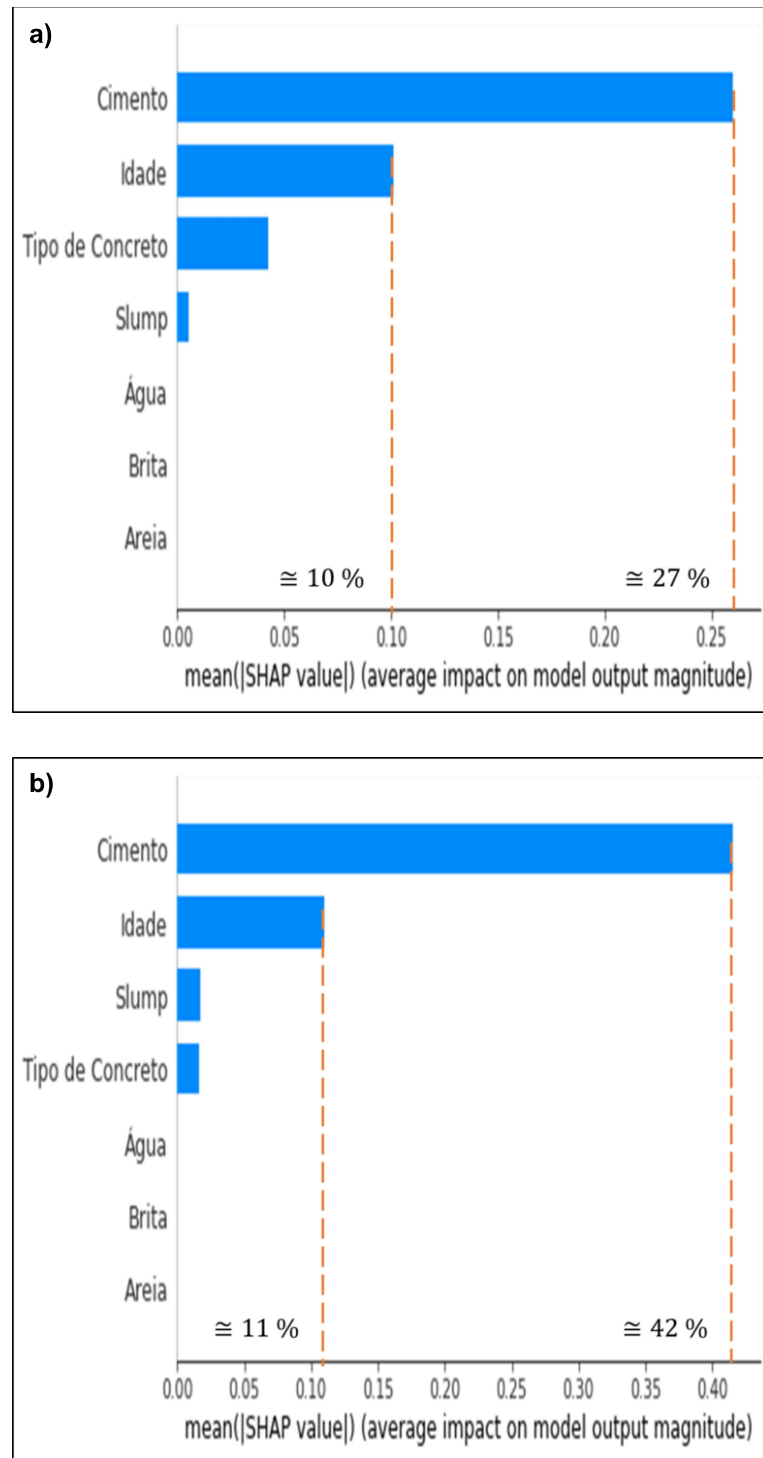
Fonte: Autora (2021)

Os resultados da predição das resistências dos concretos do *data set* 1 mostram que a maioria dos modelos tiveram uma acurácia acima de 90 %. Apenas os modelos de regressões Ridge e LASSO apresentaram valor inferior, com  $R^2$  de 85 % para a resistência  $f_{ck}$ . Já para a resistência  $f_{ct}$  os modelos Ridge e RNA apresentaram o menor valor de acurácia de 90 %. Os modelos que apresentaram maiores valores para  $R^2$  para a resistência  $f_{ck}$  foram RNA com  $R^2$  de 94 % e Mínimos Quadrado Ordinários (MQO) com  $R^2$  de 95 %. Para a resistência  $f_{ct}$  os modelos de regressão Linear Múltipla (RLM) e regressão Bayesiana apresentaram o valor de  $R^2$  de 97 %.

Em relação às métricas de erro, a maioria dos modelos apresentaram valores próximos de 0,01 e 0,08. Os modelos que apresentaram maiores valores de erro foram RNA, KNN e LASSO para ambas as resistências mecânicas.

A Figura 38 apresenta as variáveis que têm maior influência na predição da resistência mecânica dos concretos produzidos com estéril de nióbio.

**Figura 38 – Análise de influência das variáveis nos modelos treinados do *Data Set 1*. a) Resistência à compressão; b) Resistência à tração.**



**Fonte: Autora (2021)**

Analisando as variáveis que tiveram maior influência na predição das resistências nos modelos, tem-se para ambos resistências que a quantidade de cimento e a idade de ruptura apresentam maior impacto nas resistências dos concretos produzidos com estéril de nióbio. Os

percentuais de influência da quantidade de cimento foram de aproximadamente 30 % ( $f_{ck}$ ) e 40 % ( $f_{ct}$ ), e para a variável idade os valores foram acima de 10 % ( $f_{ck}$  e  $f_{ct}$ ). Esses resultados corroboram com as teorias presentes na literatura sobre a importância do consumo de cimento nos concretos e sobre o alto ganho de resistência nas primeiras idades de cura. Os resultados também confirmam sobre os valores de correlação entre as variáveis preditoras e as resistências mecânicas encontradas nas análises estatísticas realizadas nesse estudo sobre os concretos produzidos com estéril de nióbio.

Ziolkowski e Niedostatkiewicz (2019) também observaram que a quantidade de cimento tem maior percentual de impacto na predição da resistência de concretos, usando como ferramenta de predição modelos de RNA. Já no trabalho de Zhang, Li e Wang (2020) usando os modelos de regressão de árvores DT, RF e *Gradient Boosting* para predição de concretos a variável idade é a variável que apresenta maior fator de influência na resistência dos concretos preditos.

#### 4.7.2 Algoritmos de Aprendizagem Aplicados ao *Data Set 2*


Os resultados obtidos para a predição dos concretos quanto sua resistência à compressão ( $f_{ck}$ ) são apresentados a seguir. Na Tabela 13 estão expressos os valores máximos e mínimos obtidos na simulação do *data set 2* para o conjunto de dados com e sem *outliers*. A Figura 39 mostra os valores do coeficiente de determinação  $R^2$  e a Figura 40 os valores obtidos para os erros de cada modelo.

**Tabela 13 – Resultados da predição dos concretos para o *Data Set 2***

RESISTÊNCIAS	VALORES	TREINO $R^2$	TESTE $R^2$	MSE	MAE	RMSE
$f_{ck}$	Max	0,92	0,83	22,45	3,76	4,73
	Min	0,60	0,60	9,4	2,34	3,06
$f_{ck}$ - outlier	Max	0,94	0,87	21,68	3,94	4,82
	Min	0,60	0,61	2,3	1,91	2,79


**Fonte: Autora (2021)**


Figura 39– Coeficiente de determinação R<sup>2</sup> dos modelos na predição da resistência à compressão (f<sub>ck</sub>) do Data Set 2 com e sem outlier



Fonte: Autora (2021)

Figura 40 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão (f<sub>ck</sub>) com e sem outlier do Data Set 2






Fonte: Autora (2021)

Os resultados da predição das resistências dos concretos do *data set 2* foram inferiores do que os valores encontrados para o *data set 1*. Isso se justifica devido à heterogeneidade dos dados e grande variação entre os valores dos parâmetros de entrada. Todos os modelos tiveram melhores resultados de acurácia e minimização dos erros com a exclusão dos *outliers*. Os melhores resultados de predição foram obtidos para os modelos *Gradient Boosting* e *XGBoosting* usando o ajuste de hiperparâmetro *grid search*, com  $R^2$  de 87 %. Já os modelos LASSO e SVM apresentaram os menores valores de acurácia de 61 % e 60 % e maiores erros. Esses resultados apontam que os modelos *Gradient Boosting* e *XGBoosting* têm maior capacidade de generalização e precisão de predição para conjuntos de dados heterogêneos, com grande quantidade de variáveis de entrada e maior quantidade de amostras (1517 – *data set 2*), do que conjuntos com dados mais homogêneos, menor amostra (128 – *data set 1*) e variação entre os valores observados.

Resultados semelhantes são encontrados nos trabalhos de Cui *et al.* (2021) e Nguyen-Sy *et al.*, (2020), que apontam esses dois modelos como melhores métodos de predição da resistência de concretos do que os modelos SVM, RF, DT, RNA e RLM. Cui *et al.* (2021) também ressalta sobre eficácia na predição da resistência de concretos usando algoritmos de ajuste de hiperparâmetros para o modelo *XGBoosting*.

A Figura 41 apresenta as variáveis que têm maior influência na predição da resistência mecânica dos concretos do *data set 2*.

**Figura 41 – Análise de influência das variáveis nos modelos treinados para o *Data Set 2***



Fonte: Autora (2021)

As variáveis que tiveram maior influência na predição das resistências nos modelos foram a idade de ruptura com aproximadamente 35 % de impacto e a relação a/c com aproximadamente 30 %. Esses resultados apontam sobre a importância da quantidade de água na mistura dos concretos para o ganho de resistência nas primeiras idades de cura (METHA; MONTEIRO, 2008). Os resultados também confirmam sobre as correlações encontradas entre essas variáveis preditoras e as resistências mecânicas nas análises estatísticas.

No trabalho de Nunez e Nehdi (2021) sobre o estudo da resistência mecânica e carbonatação de concretos produzidos com resíduo de construção e demolição (RCD) usando o algoritmo de *Gradient Boosting*, também aponta a relação a/c como a principal variável que impacta na predição da resistência de concretos, com uma porcentagem de 60 %.

#### 4.7.3 Algoritmos de Aprendizagem Aplicados ao Grupo A


O grupo A é constituído com 697 amostras de concretos agrupados no intervalo de relação a/c de 0,45 a 0,54. Os dados de entrada usados nesse grupo foram: tipos de agregados (basalto, calcário, diabásio, dolomito, estéril de nióbio, gnaiss, granito, granulito, micaxisto, seixo lavado, seixo misto, sienito e traquito), tipos de cimentos (CP I S 32, CP II E 32, CP II F 32, CP II F 40, CP II Z 32, CP III RS 40, CP IV 32 e CP V ARI), relação a/c, areia, brita e aditivo, totalizando 27 diferentes variáveis predictoras. Na Tabela 14 são expressos os valores máximos e mínimos obtidos na simulação deste conjunto de dados com e sem *outliers*. A Figura 42 apresenta os valores do coeficiente de determinação  $R^2$  e a Figura 43 os valores dos erros de cada modelo.

**Tabela 14 – Resultados da predição dos concretos para o grupo A**

RESISTÊNCIAS	VALORES	TREINO $R^2$	TESTE $R^2$	MSE	MAE	RMSE
$f_{ck}$	Max	0,92	0,84	26,18	4,03	5,11
	Min	0,60	0,57	9,81	2,23	3,13
$f_{ck}$ - outlier	Max	0,92	0,83	22,45	3,76	4,73
	Min	0,60	0,60	9,39	2,37	3,06


Fonte: Autora (2021)

**Figura 42 – Coeficiente de determinação  $R^2$  dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem *outlier* do grupo A**



Fonte: Autora (2021)

Figura 43 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem outlier do grupo A



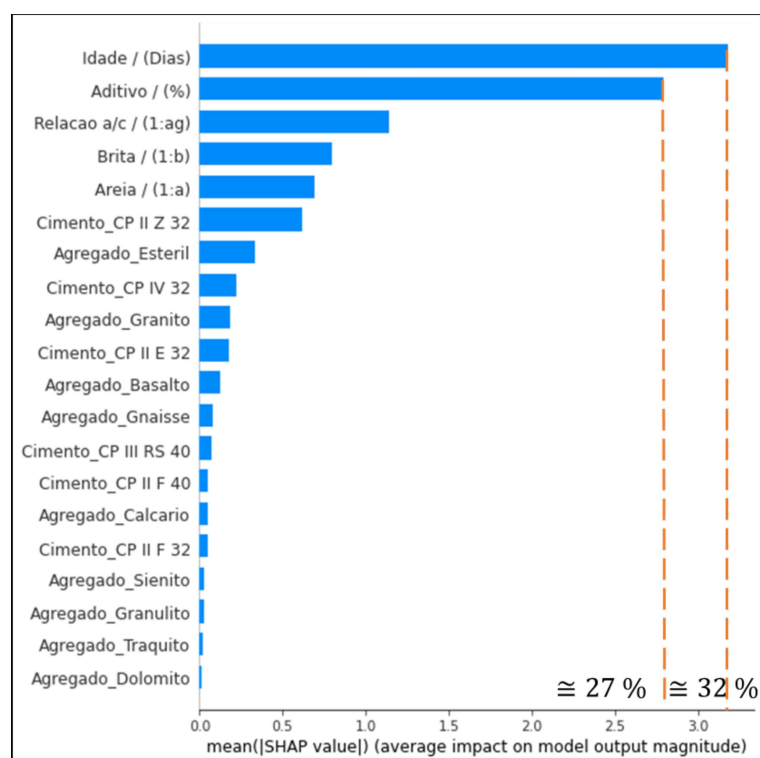
Fonte: Autora (2021)

Os resultados obtidos na predição das resistência dos concretos do grupo A foram inferiores do que os valores encontrados para os *data sets* 1 e 2, com  $R^2$  variando entre 57 % e 84 %. Alguns modelos apresentaram menores valores de acurácia após a extração dos *outliers* no conjunto de dados (RNA, *XGBoosting*, *Gradient Boosting*, RF, DT e KNN). Entretanto, os valores encontrados para os erros foram menores do que com a presença dos *outliers*. Os modelos que apresentaram melhores resultados de acurácia na predição da resistência dos concretos foram *Gradient Boosting* (83 %) e *XGBoosting* (84 %). Vale ressaltar que o uso do algoritmo de ajuste de hiperparâmetros *grid search* não proporcionou melhora na acurácia

desses modelos. Os modelos que apresentaram menores valores de acurácia foram regressão LASSO (57 %) e SVM (60 %), os maiores erros foram os modelos RNA e LASSO para o conjunto de dados normal, LASSO e MQO para os conjuntos de dados sem *outliers*. Esses resultados indicam que os valores presentes neste grupo não apresentam uma boa amostragem para o ajuste dos modelos no estudo da resistência à compressão dos concretos compilados na literatura com os concretos produzidos com estéril de nióbio.

A Figura 44 apresenta as variáveis que têm maior influência na predição da resistência mecânica dos dados dos concretos do grupo A.

**Figura 44 – Análise de influência das variáveis nos modelos treinados para o grupo A**



**Fonte: Autora (2021)**

As variáveis que apresentaram maior percentual de influência na predição das resistências nos modelos foram a idade de ruptura com valor acima de 30 % de impacto e o aditivo com aproximadamente 28 %. Esses resultados mostram que tanto o tempo de maturação dos concretos, quanto o uso de aditivo na mistura, apresentam uma forte correlação positiva com a resistência à compressão dos concretos usados neste grupo.

No trabalho de Nguyen-Sy *et al.* (2020) sobre o estudo da resistência mecânica de concretos produzidos com adição de cinzas, usando os algoritmos de *Gradient Boosting* e *XGBoosting*, também encontraram que as variáveis que possui maior percentual de influência na resistência mecânica foram a relação a/c, a idade dos concretos e o uso de aditivo superplastificante. O uso deste tipo de aditivo proporciona ao concreto uma alta dispersão entre agregados e cimento, e a redução da água na dosagem dos concretos, o que evidencia os altos valores encontrados resistência  $f_{ck}$  de até 65 MPa para uma relação a/c de 0,46, presentes nas amostras deste grupo A.

#### 4.7.4 Algoritmos de Aprendizagem Aplicados ao Grupo B


O grupo B é constituído com 726 amostras de concretos agrupados no intervalo de relação a/c de 0,55 a 0,64. Os dados de entrada usados nesse grupo foram: tipos de agregados (basalto, calcário, diabásio, dolomito, estéril de nióbio, gnaiss, granito, granulito, quartzo, seixo lavado, seixo misto, seixo rolado, sienito e traquito), tipos de cimentos (CP I S 32, CP II E 32, CP II F 32, CP II F 40, CP II Z 32, CP III RS 40, CP IV 32 e CP V ARI), relação a/c, areia, brita e aditivo, totalizando 27 diferentes variáveis preditoras. Na Tabela 15 são expressos os valores máximos e mínimos obtidos na simulação deste conjunto de dados com e sem *outliers*. A Figura 45 apresenta os valores do coeficiente de determinação  $R^2$  e a Figura 46 os valores dos erros de cada modelo.

**Tabela 15 – Resultados da predição dos concretos para o grupo B**

RESISTÊNCIAS	VALORES	TREINO $R^2$	TESTE $R^2$	MSE	MAE	RMSE
$f_{ck}$	Max	0,95	0,88	15,62	2,99	3,95
	Min	0,60	0,59	4,41	1,41	2,1
$f_{ck}$ - outlier	Max	0,93	0,88	13,08	3,03	3,77
	Min	0,62	0,58	4,46	1,43	2,11

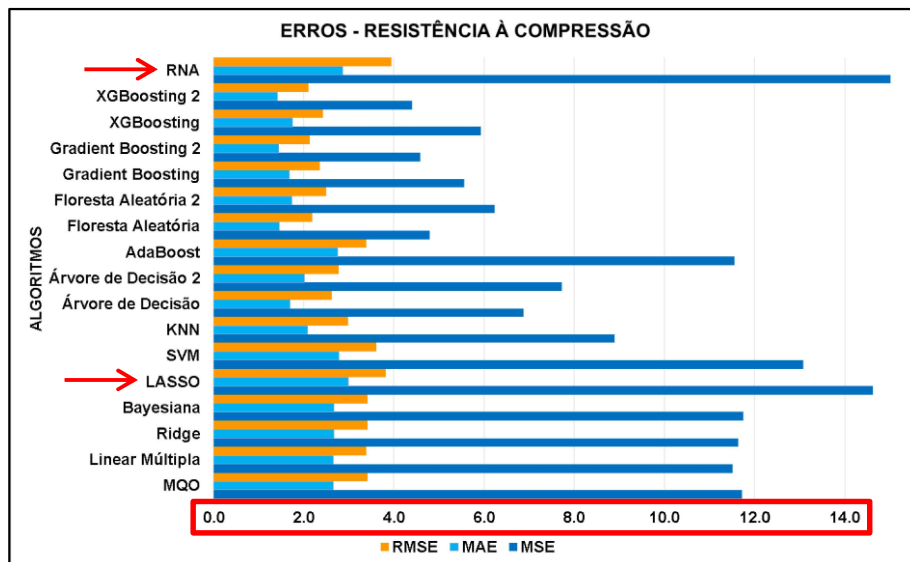
Fonte: Autora (2021)


Figura 45 – Coeficiente de determinação  $R^2$  dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem outlier do grupo B



Fonte: Autora (2021)

Figura 46 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem outlier do grupo B






Fonte: Autora (2021)

Os resultados obtidos na predição das resistências dos concretos do grupo B foram semelhantes ao *data set 2*, com valores de  $R^2$  inferiores aos valores encontrados para os *data sets 1*, com  $R^2$  variando entre 58 % e 87 %. Analogamente ao grupo A, nesse grupo a maioria dos modelos apresentaram menores valores de acurácia após a extração dos *outliers* no conjunto de dados e menores valores para os erros após a extração dos *outliers* no conjunto de dados. Os modelos que apresentaram melhores resultados de acurácia na predição da resistência dos concretos foram *Gradient Boosting* (87 %) e *XGBoosting* (88 %) usando o ajuste de hiperparâmetros *grid search*. Os modelos que apresentaram menores valores de acurácia também foram a regressão LASSO (58 %) e SVM (62 %), os maiores erros observados foram para os modelos RNA e LASSO para o conjunto de dado normal, e SVM e RLM para os conjuntos de dados sem *outliers*. Assim como no grupo A, os resultados obtidos na simulação do grupo B não apresentam uma boa amostragem para o ajuste dos modelos no estudo da resistência à compressão dos concretos compilados na literatura com os concretos produzidos com estéril.

A Figura 47 apresenta as variáveis que têm maior influência na predição da resistência mecânica dos dados dos concretos do grupo B.

**Figura 47 – Análise de influência das variáveis nos modelos treinados para o grupo B**



Fonte: Autora (2021)

As variáveis que apresentaram maior percentual de influência na predição das resistências nos modelos foram a idade de ruptura com valor aproximado de 35 % de impacto e o cimento CP II Z 32 com aproximadamente 13 %. Esses resultados mostram que tanto o tempo de maturação dos concretos, quanto o uso de cimento CP II Z 32 na mistura, apresentam correlações positivas com a resistência à compressão dos concretos usados neste grupo.

#### 4.7.5 Algoritmos de Aprendizagem Aplicados ao Grupo C

O grupo C é constituído com 271 amostras de concretos agrupados no intervalo de relação a/c de 0,65 a 0,74. Os dados de entrada usadas nesse grupo foram: tipos de agregados (basalto, calcário, estéril de nióbio, gnaisse, granito, micaxisto, quartzo, e traquito), tipos de cimentos (CP II E 32, CP II F 32, CP II F 40, CP II Z 32, CP III 32, CP III RS 40, CP IV 32 e CP V ARI), relação a/c, areia, brita e aditivo, totalizando 21 diferentes variáveis preditoras. Na Tabela 16 são expressos os valores máximos e mínimos obtidos na simulação deste conjunto


de dados com e sem *outliers*. A Figura 48 apresenta os valores do coeficiente de determinação  $R^2$  e a Figura 49 os valores dos erros de cada modelo.

**Tabela 16 – Resultados da predição dos concretos para o grupo C**

RESISTÊNCIAS	VALORES	TREINO $R^2$	TESTE $R^2$	MSE	MAE	RMSE
$f_{ck}$	Max	0,98	0,93	11,07	2,51	3,32
	Min	0,65	0,63	1,96	0,78	1,4
$f_{ck}$ - outlier	Max	0,98	0,93	10,18	2,54	3,19
	Min	0,68	0,65	1,92	0,77	1,39


Fonte: Autora (2021)

**Figura 48 – Coeficiente de determinação  $R^2$  dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem outlier do grupo C**



Fonte: Autora (2021)

Figura 49 – Erros RMSE, MAE e MSE dos modelos na predição da resistência à compressão ( $f_{ck}$ ) com e sem *outlier* do grupo C



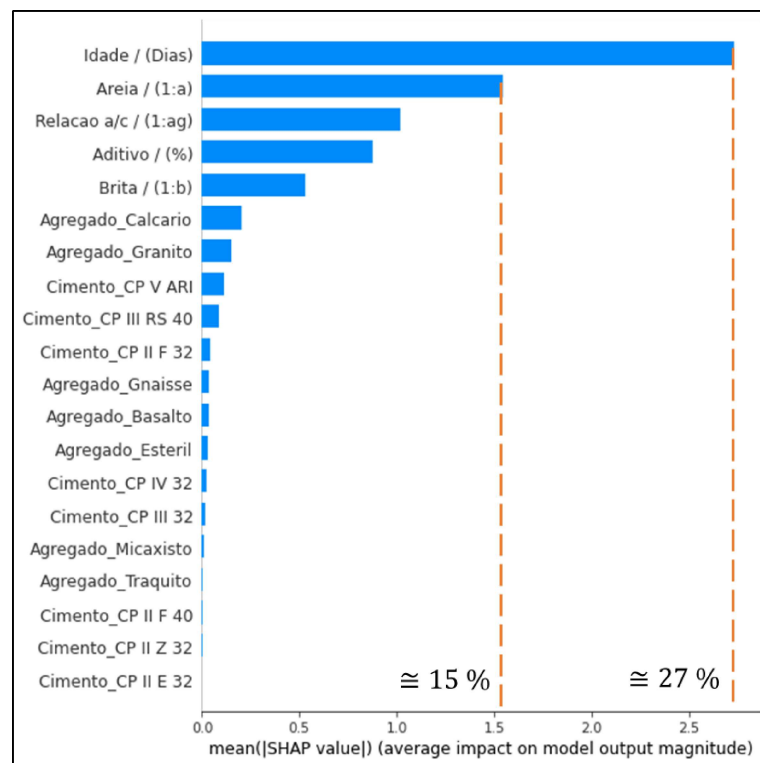
Fonte: Autora (2021)

Dos três conjuntos agrupados do *data set 2*, o grupo C foi o que apresentou melhores valores de acurácia na predição de resistência dos concretos compilados na literatura versus os concretos produzidos com estéril de nióbio. A maioria dos modelos apresentaram acurácia entre 72 % e 93 % de predição da resistência à compressão. Os modelos que apresentaram melhores valores de  $R^2$  foram RF e *XGBoosting 2* (93 %) com e sem a presença de *outliers*. Os modelos que apresentaram menores valores de acurácia também foram a regressão LASSO (65 %) e SVM (63 %), maiores erros observados foram para os as regressões SVM e LASSO para o conjunto de dado normal, e LASSO para os conjuntos de dados sem *outliers*. Nesse conjunto,

embora a maioria dos modelos tenham apresentado aumento nos valores do coeficiente de determinação  $R^2$  com a extração dos *outliers* no conjunto de dados, ainda há modelos que apresentaram a diminuição do coeficiente  $R^2$  (LASSO, KNN e *AdaBoost*). Nesse grupo C vale ressaltar que foi obtido melhores valores de acurácia e erro, quando comparado também ao *data set 2*.

A Figura 50 apresenta as variáveis que têm maior influência na predição da resistência mecânica dos dados dos concretos do grupo C.

**Figura 50 – Análise de influência das variáveis nos modelos treinados para o grupo C**



Fonte: Autora (2021)

As variáveis que apresentaram maior percentual de influência na predição das resistências nos modelos foram a idade de ruptura com valor aproximado de 25 % de impacto e a areia com valor acima de 15 %. Esses resultados mostram que tanto o tempo de maturação dos concretos, quanto a quantidade de areia usada na mistura, apresentam correlações positiva com a resistência à compressão dos concretos usados neste grupo.

#### 4.7.6 Análise dos Resíduos dos Modelos

Os dois melhores resultados e modelos de predição da resistência dos concretos para cada conjunto de dados simulados são apresentados na Tabela 17.

**Tabela 17 – Melhores modelos de predição da resistência dos concretos**

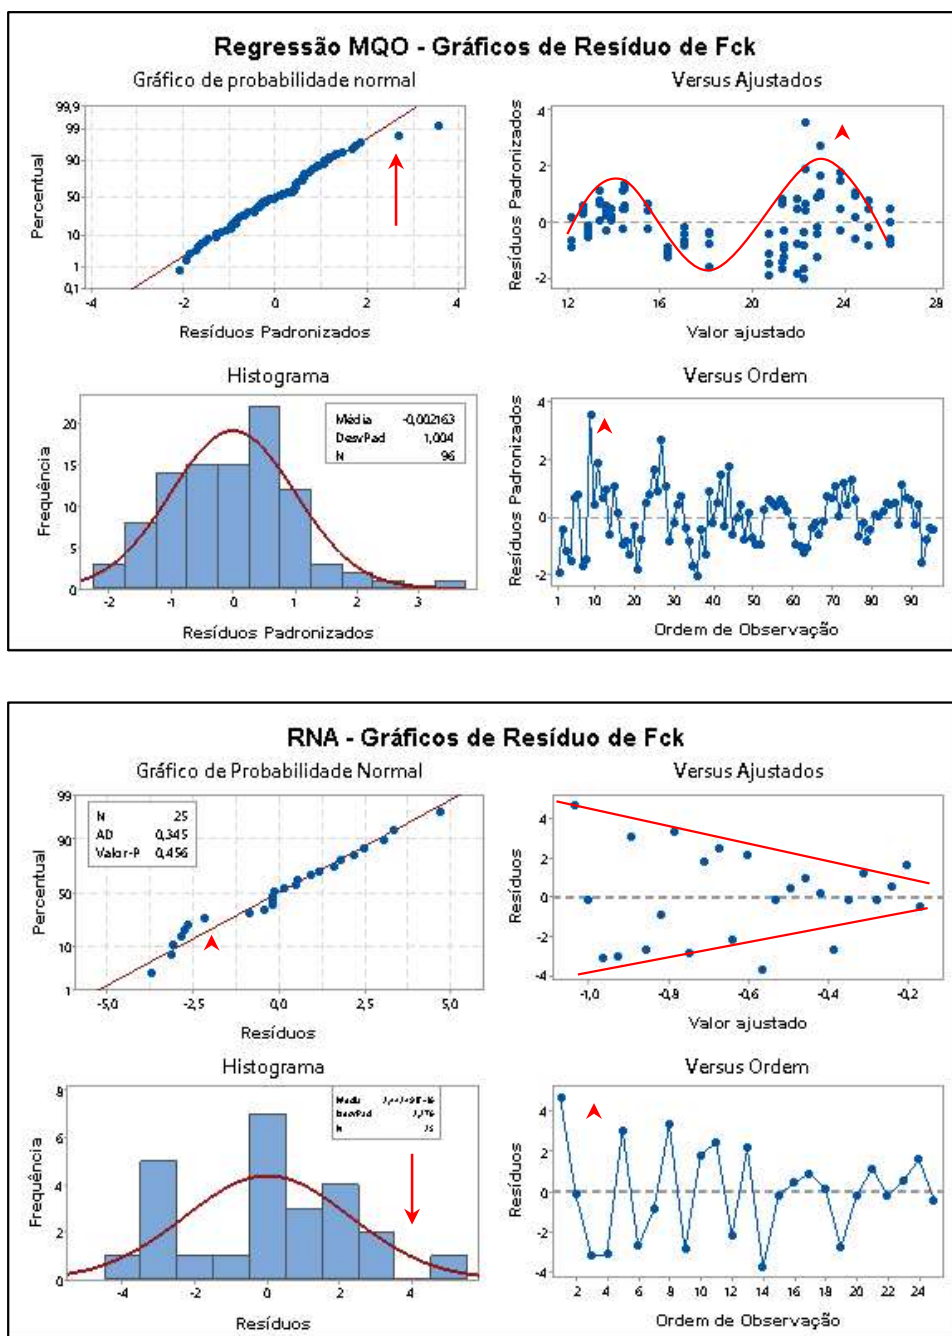
DATA SETS	ALGORITMOS	R <sup>2</sup>	MSE	MAE	RMSE
Data set 1 - f <sub>ck</sub>	MQO	0,95	0,01	0,06	0,08
	RNA	0,94	1,55	1,10	1,24
Data set 1 - f <sub>ct</sub>	Linear Múltipla	0,97	0,01	0,07	0,08
	Bayesiana	0,97	0,01	0,07	0,08
Data set 2	<i>Gradient Boosting 2</i>	0,87	7,80	1,91	2,79
	<i>XGBoosting 2</i>	0,87	7,97	1,95	2,82
Grupo A	<i>XGBoosting</i>	0,84	9,81	2,41	3,13
	<i>Gradient Boosting 2</i>	0,83	9,96	2,23	3,15
Grupo B	<i>XGBoosting 2</i>	0,88	4,41	1,41	2,10
	<i>Gradient Boosting 2</i>	0,87	4,80	1,46	2,19
Grupo C	<i>XGBoosting</i>	0,93	1,96	0,78	1,40
	Floresta Aleatória	0,93	1,99	0,79	1,41

**Fonte: Autora (2021)**

Os métodos de ML que apresentaram melhores resultados para o *data set 1* foram os modelos de RNA e regressões lineares (MQO, RLM e Bayesiana). Esse resultado indica que os métodos lineares apresentam uma boa precisão para conjuntos de dados com maior homogeneidade. Além disso, conforme observado nas análise estatísticas, a normalidade das variáveis preditoras e de predição contribuem para uma melhor precisão na predição dos modelos na resistência mecânica dos concretos produzidos com estéril de nióbio.

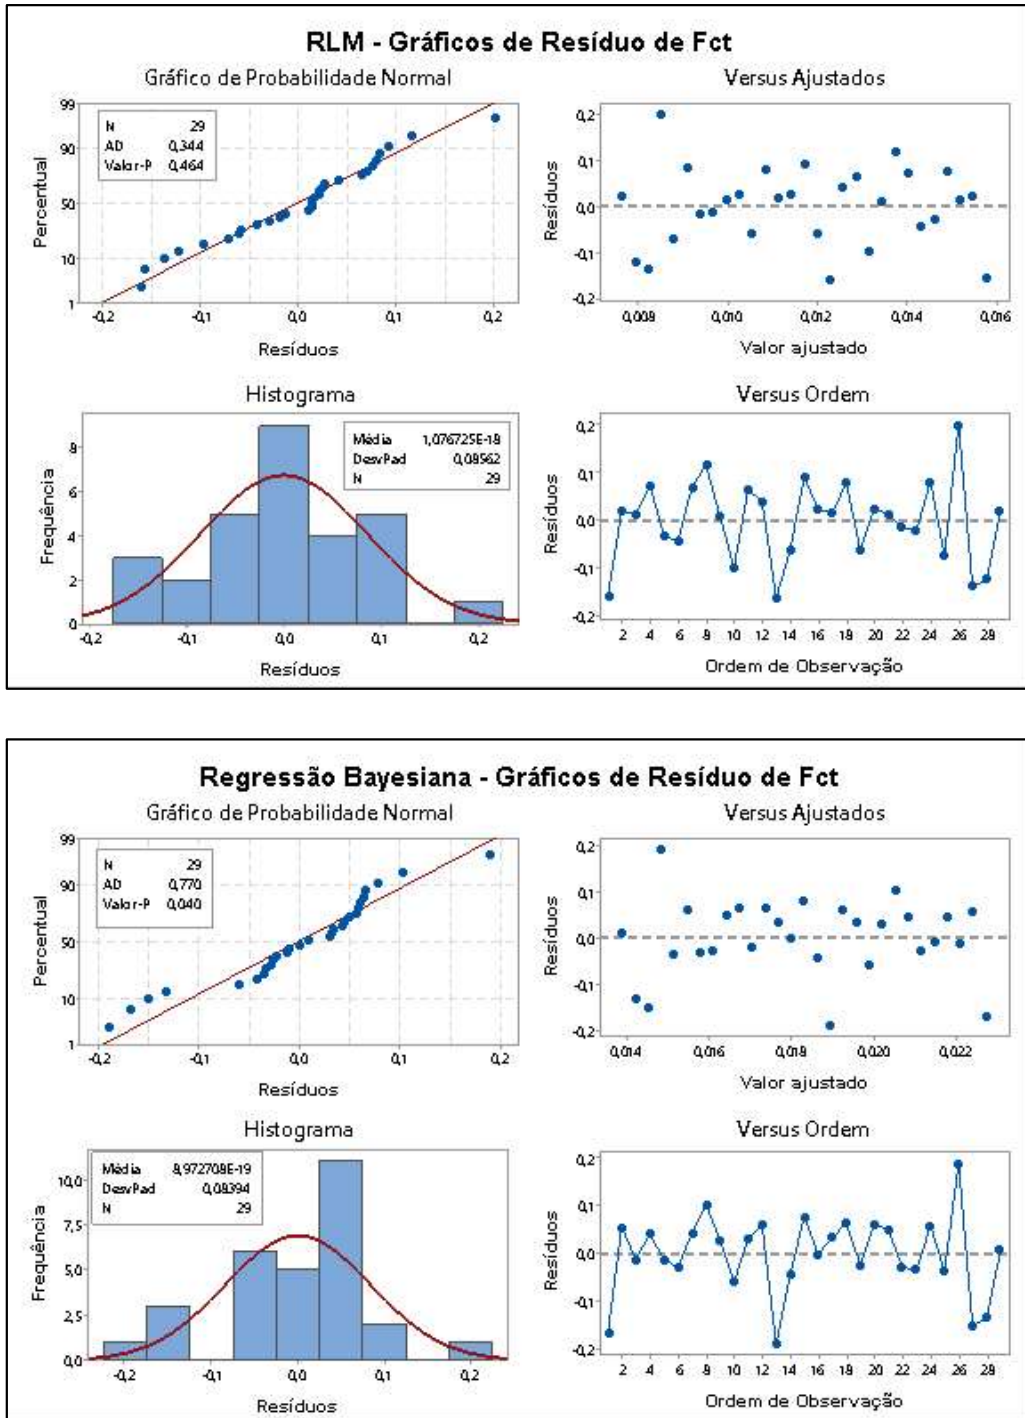
Os melhores valores para R<sup>2</sup> foram os métodos de *Gradient Boosting*, *XGBoosting* e Floresta Aleatória para os conjuntos de dados compilados da literatura. Notas - se que para conjuntos de dados que apresentam maior heterogeneidade dos valores observados esses métodos se destacam, ainda mais pela possibilidade de usar algoritmos de otimização de hiperparâmetros como o *grid search*. Comparando os métodos de erros, a métrica MAE foi o que apresentou menores valores do que MSE e RMSE. A seguir são apresentados os gráficos dos resíduos desses modelos.

Figura 51 – Gráficos dos resíduos para a predição da resistência à compressão dos concretos do *Data Set 1*



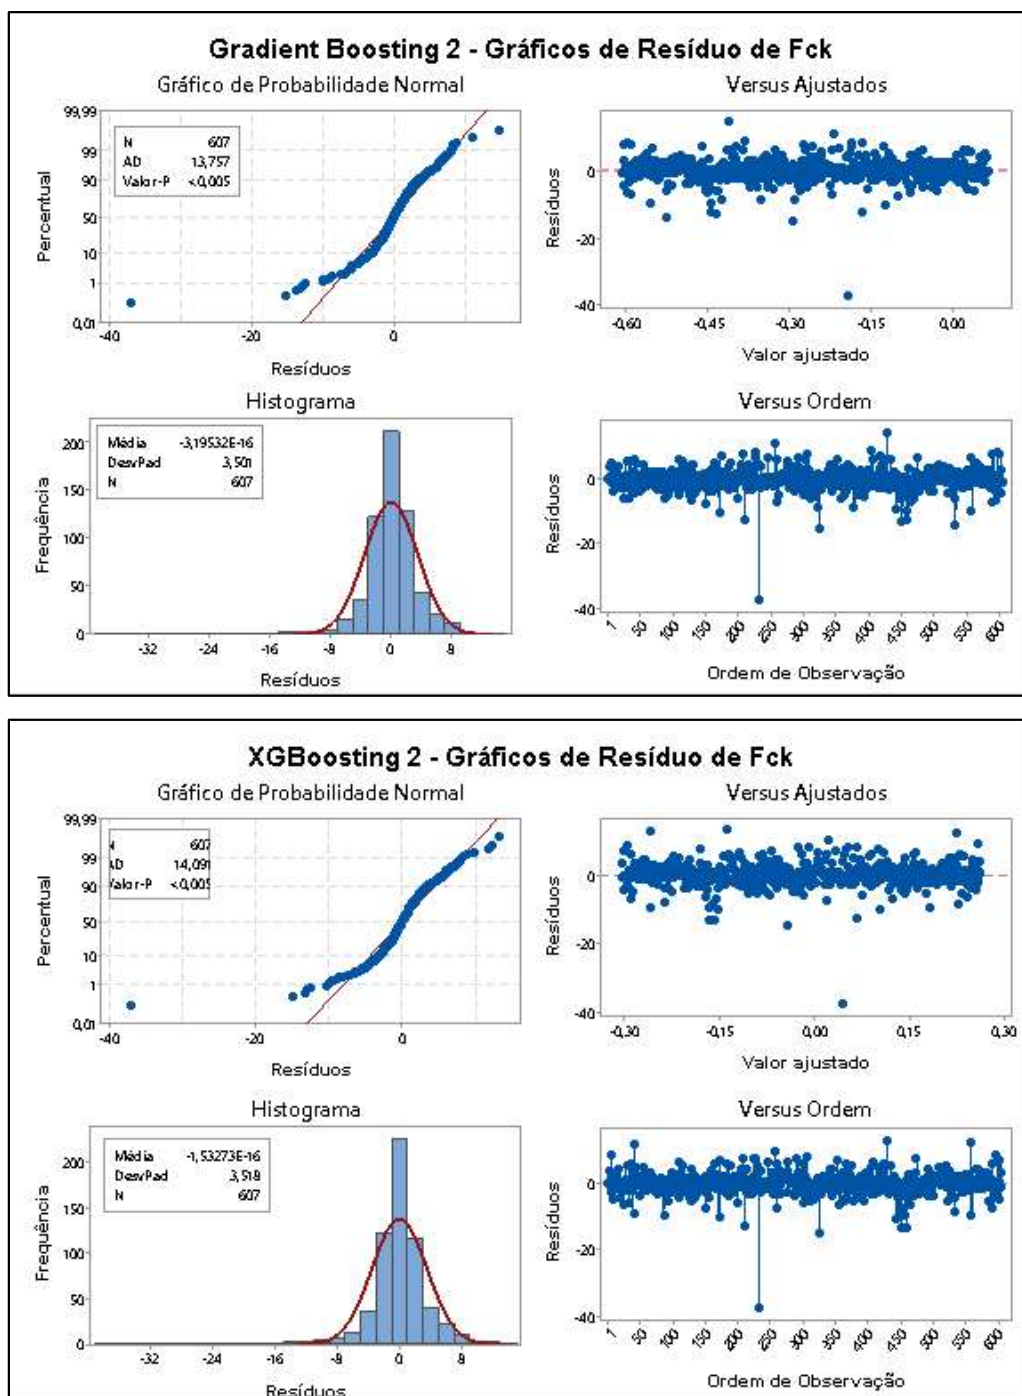
Fonte: Autora (2021)

Figura 52 – Gráficos dos resíduos para a predição da resistência à tração dos concretos do *Data Set 1*



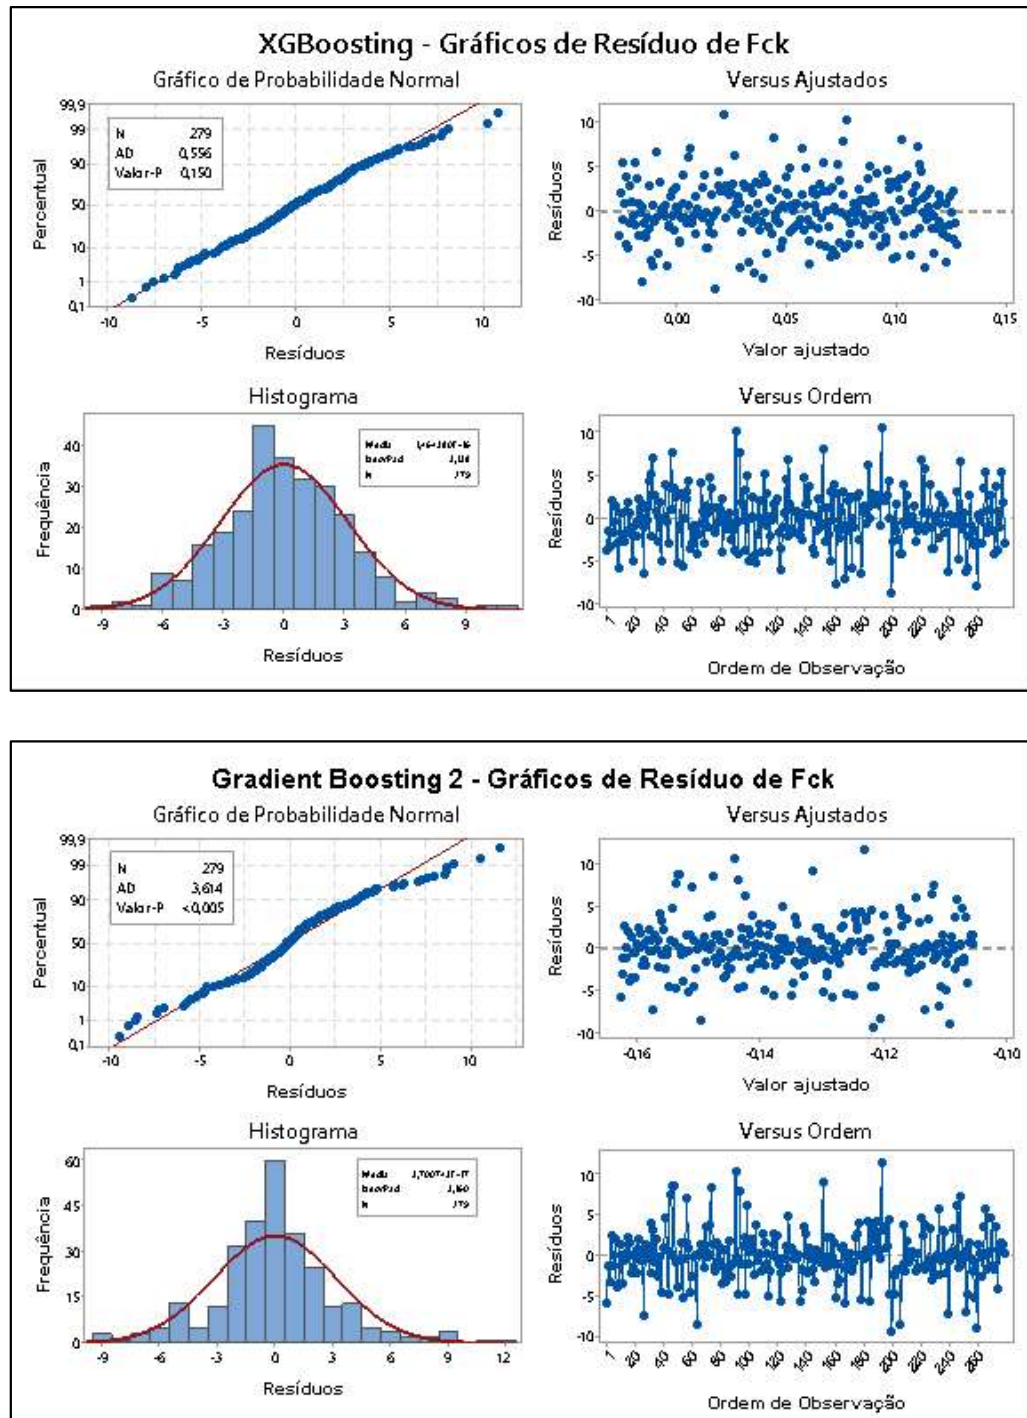
Fonte: Autora (2021)

Figura 53 – Gráficos dos resíduos para a predição da resistência à compressão dos concretos do *Data Set 2*



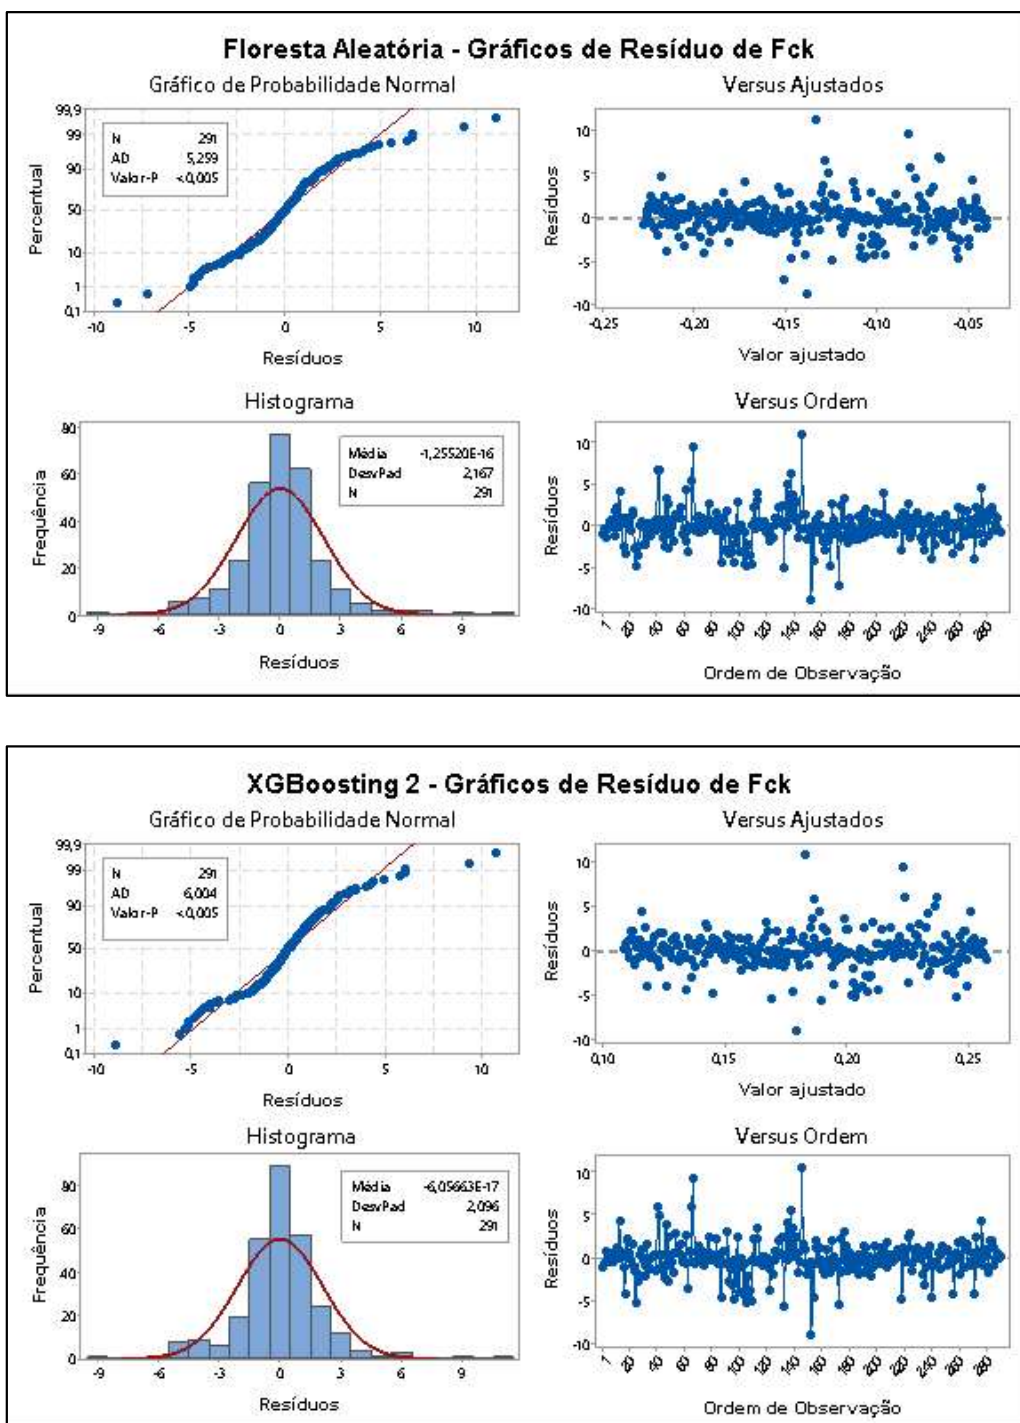
Fonte: Autora (2021)

Figura 54 – Gráficos dos resíduos para a predição da resistência à compressão dos concretos do grupo A



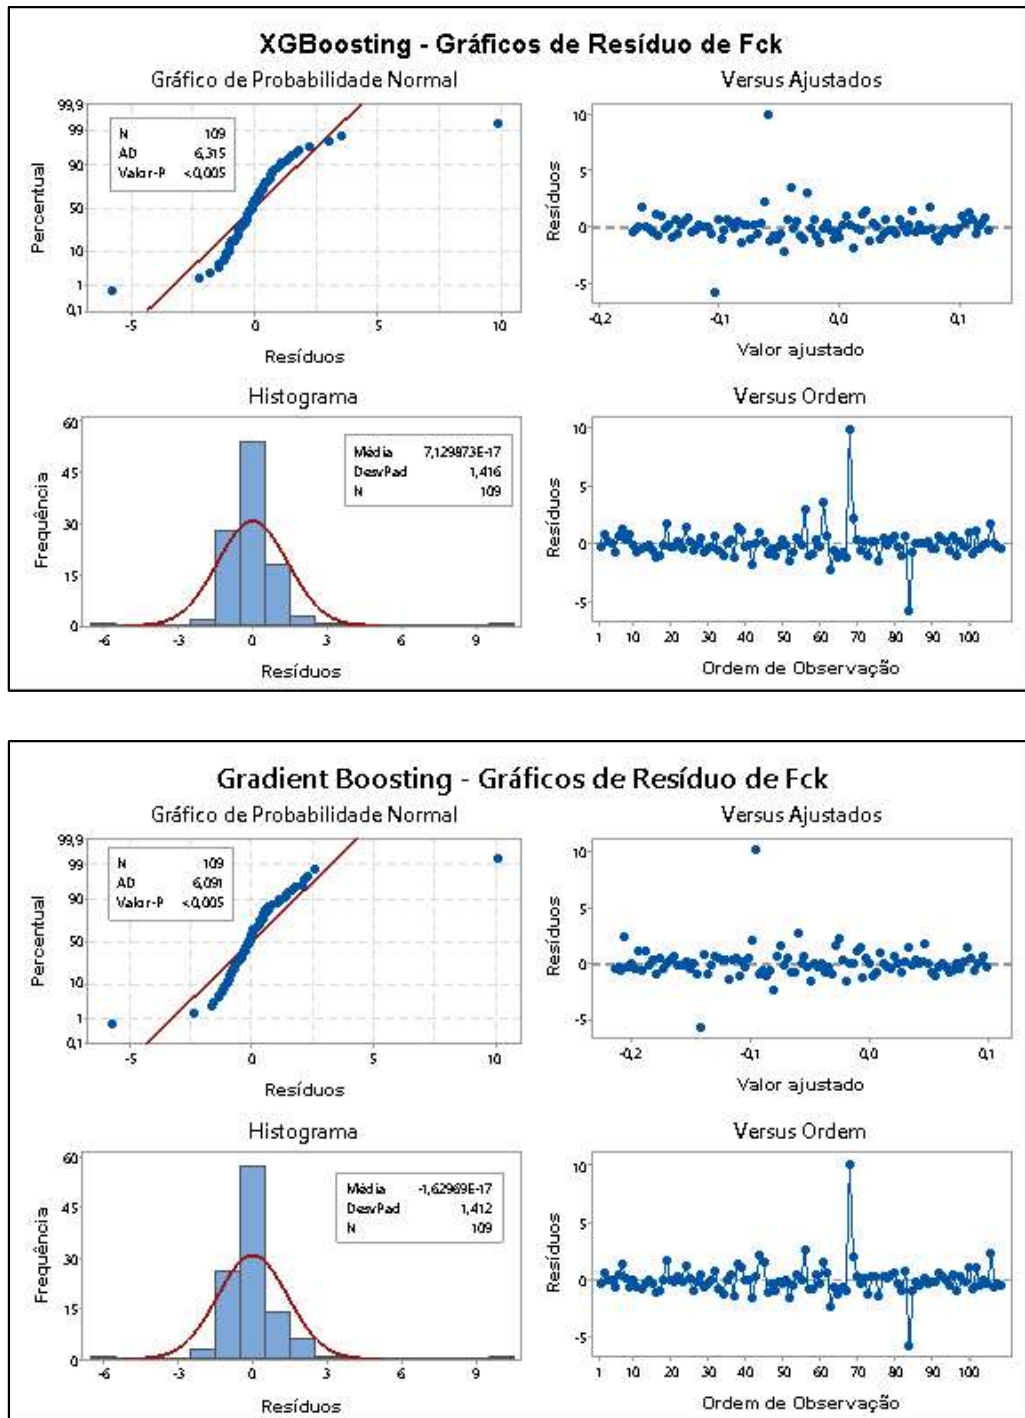
Fonte: Autora (2021)

Figura 55 - Gráficos dos resíduos para a predição da resistência à compressão dos concretos do grupo B



Fonte: Autora (2021)

Figura 56 - Gráficos dos resíduos para a predição da resistência à compressão dos concretos do grupo C



Fonte: Autora (2021)

Analisando os histogramas dos resíduos dos modelos, percebe-se que os modelos que apresentam encurtamento da cauda e assimetria à esquerda (*data set 2*) ou achatamento da curva de distribuição normal (grupos A e B), exibiram menores valores de precisão da resistência mecânica dos concretos.

Nos gráficos de probabilidade dos resíduos observa-se que apenas o modelo de *XGBoosting* do grupo A apresenta distribuição normal, todos os outros modelos não apresentam normalidade, o que reforça a falta de um ajuste de 100 % dos modelos na predição da resistência dos concretos estudados.

Em relação aos gráficos de resíduos versus ordem e resíduos versus ajuste, a maioria das observações estão localizadas próxima da linha central, apenas o grupo A apresenta maior dispersão dos dados em relação à linha central. Entretanto nota-se que em todos os gráficos de resíduos existem dados atípicos (*outliers*) que estão distantes da reta de ajuste central. Observa-se ainda que os valores observados não possuem uma variação constante, o que também confirma a falta de um melhor ajuste dos modelos na predição da resistência mecânica dos concretos estudados.

#### **4.8 Análise das Estimativas dos Modelos**

De modo geral, os conjuntos que apresentaram melhores resultados de acurácia dos modelos foram o *data set 1* e o grupo C, que apresentam maior homogeneidade dos dados amostrais do que os outros conjunto de dados analisados, o que pode ter contribuído para os modelos exibirem uma melhor aproximação dos dados preditos com os dados observados.

Em relação à determinação das resistências  $f_{ck}$  e  $f_{ct}$  no *data set 1*, tem-se que a resistência à tração apresentou maior acurácia (97 %) e valores próximos para os erros medidos. Analisando o desempenho dos grupos A, B e *data set 2*, percebe-se que a falta de ajuste dos modelos nesses conjuntos está associada a não normalidade dos dados, existência de *outliers* e ainda a heterogeneidade dos dados adotados para compor estes conjuntos.

Analisando os valores dos erros obtidos pelos métodos de ML, verificou-se que os conjuntos que apresentaram valores atípicos, tiveram uma minimização dos resultados com a extração dos *outliers*. Outra observação relevante sobre a exclusão dos *outliers* dos conjuntos, é a falta de ajuste para alguns modelos. Este fato pode ser melhor compreendido através da análise dos resíduos, onde verifica-se que a não normalidade dos mesmos e a alta variação entre os valores preditos versus valores observados, fez com que não ocorresse um bom ajuste de alguns modelos na simulação dos grupos A, B e C.


Em relação às técnicas de ML tem-se que os modelos que exibiram melhor acurácia e menores erros para os *data sets* com maior heterogeneidade dos dados, foram os algoritmos *Gradient Boosting* e o *XGBoosting*. Conforme apontado por diversos autores em trabalhos semelhantes sobre a predição de resistência de concretos, esses métodos *ensembles* apresentam maior capacidade de aprendizado e generalização quando comparados a outras técnicas de ML, como: RNA, SVM, RLM e MQO. Do mesmo modo, verificou-se que o uso do algoritmo de ajuste de hiperparâmetros *grid search* também proporciona uma melhora na precisão das predições de resistência dos concretos (AHMAD *et al.*, 2021; CUI *et al.*, 2021; ERDAL, 2013; ERDAL; KARAKURT; NAMLI, 2013; NGUYEN *et al.*, 2021a).


Já para os *data sets* com amostras homogêneas (*data set 1*), os modelos de regressão linear (RLM, MQO e Bayesiana) e RNA apresentaram bons resultados de predição, principalmente com o baixo valor de erro calculados.

#### 4.9 Análise das Influência das Variáveis Predictoras

A Figura 57 apresenta as duas variáveis que apresentam maior influência na predição da resistência dos concretos analisados.

**Figura 57 – Principais variáveis que apresentam maior influência na predição dos modelos de ML**





Fonte: Autora (2021)

Nota-se que para os todos os conjuntos analisados a variável idade foi o que exibiu maior contribuição média na predição dos modelos, principalmente para os conjuntos de dados com amostras heterogêneas. Como citado anteriormente, a idade de maturação dos concretos apresenta um alto ganho de resistência mecânica nas primeiras idade de cura (CASTRO, 2017; FERNANDES; BITTENCOURT; HELENE, 2011).

Analisando as outras variáveis preditoras que apresentaram maior impacto na predição dos concretos (quantidade de cimento, relação a/c, aditivo, areia e o cimento CP II Z 32), percebe-se que para os conjuntos de dados homogêneos (*data set 1*) a quantidade de cimento foi o que apresentou maior influência na predição da resistência mecânica. Já para os conjuntos de dados heterogêneas (*data set 2*, grupos A, B e C) as variáveis que apresentam maior percentual de impacto na predição da resistência dos concretos são as mesmas que apresentam maior poder de correlação entre as variáveis preditoras e as resistências mecânicas. Esse resultado pode estar associado ao quantitativo dessas variáveis presente nos conjuntos, bem como a interação entre os materiais usados na dosagem dos concretos analisados.

## 5. CONCLUSÃO

A presente pesquisa analisou a viabilidade da utilização de diferentes técnicas de Inteligência Artificial para a previsão da resistência mecânica de concretos produzidos com estéril de nióbio. Os principais objetivos desta tese foram i) investigar e aplicar diferentes técnicas de aprendizagem de máquina baseados em métodos de regressão para a predição da resistência mecânica dos concretos produzidos com estéril de nióbio; ii) investigar a influência dos parâmetros (*slump test*, cimento, areia, brita, relação a/c, idade de ruptura) dos materiais utilizados na composição dos concretos produzidos com estéril de nióbio, como dados de entrada na predição da resistência à compressão ( $f_{ck}$ ) e à tração ( $f_{ct}$ ); e iii) comparar os modelos e as técnicas computacionais utilizados para predição das resistências mecânicas, avaliando seu potencial de representação com os dados obtidos experimentalmente e banco de dados com dados compilados da literatura.

Em geral, a aplicação dos métodos de ML demonstraram desempenho satisfatório para determinar a resistência à compressão dos concretos analisados, variando entre 83 % a 97 % de acurácia. As técnicas de ML que melhor predizem a resistência dos concretos foram os métodos de RLM, RNA, MQO, RF, *Gradient Boosting* e *XGBoosting*.

Os conjuntos de dados com menor quantidade de amostras (*data set 1* e grupo C), apresentaram maiores valores de acurácia e menores erros, com  $R^2$  variando entre 93 % e 97 %. Esses resultados podem estar associados à menor quantidade e homogeneidade das amostras dos conjuntos analisados. Este fato também foi observado por Vargas (2020), que ressalta sobre a diferença de precisão dos modelos em conjunto de dados com grande diversificação de valores e quantidade de dados.

Além da previsão das resistências mecânicas dos concretos, foi possível determinar as variáveis que apresentam maior contribuição de predição testados pelos modelos. As variáveis idade, relação a/c, aditivo e quantidades de cimento e areia exercem maior influência como variável de entrada e fator de predição das resistências dos concretos estudados.

Por fim, é importante reforçar que o presente estudo traz importantes contribuições científicas para a aplicação de técnicas computacionais no estudo de concretos, possibilitando minimizar os custos, materiais e tempo gasto num estudo experimental complexo, no qual é necessário realizar um extenso trabalho de produção e caracterização dos materiais, onde não

se têm muito conhecimento. Do mesmo modo, esta pesquisa também traz contribuições social, ambiental e econômico, com o favorecimento de utilização de materiais que são descartados na cidade de Catalão, para serem comercializados visando suprir a demanda do setor da construção civil regional, além de minimizar os impactos ambientais gerado pelas mineradoras e concreteiras.

### **5.1 Sugestões Para Trabalhos Futuros**

- Utilizar métodos combinados (Ensemble) visando um melhor desempenho de previsão da resistência mecânica dos concretos estudados.
- Ampliar a base de dados compilados da literatura com dados fornecidos por construtoras.
- Utilizar outros tipos de composições do concreto produzido com estéril de nióbio que representem uma maior gama de tipos/classes de concreto, a fim de gerar modelos de regressão mais precisos.
- Aplicar outros métodos de seleção de característica no processo de otimização de parâmetros para encontrar também as características mais relevantes dos materiais constituintes do concreto.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- ABU YAMAN, M.; ABD ELATY, M.; TAMAN, M. Predicting the ingredients of self compacting concrete using artificial neural network. **Alexandria Engineering Journal**, v. 56, n. 4, p. 523–532, 2017.
- ACUÑA, L. et al. Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C 39M. **Informacion Tecnologica**, v. 25, n. 4, p. 3–12, 2014.
- ADOM-ASAMOA, M.; AMPOFO, W. J.; AFRIFA, R. O. Comparative study on shear strength of reinforced concrete beams made from phyllite and granite aggregates without shear reinforcement. n. January, p. 285–299, 2012.
- AHMAD, A. et al. Comparative study of supervised machine learning algorithms for predicting the compressive strength of concrete at high temperature. **Materials**, v. 14, n. 15, 2021.
- AHMADI-NEDUSHAN, B. An optimized instance based learning algorithm for estimation of compressive strength of concrete. **Engineering Applications of Artificial Intelligence**, v. 25, n. 5, p. 1073–1081, 2012.
- AL-SHAMIRI, A. K. et al. Modeling the compressive strength of high-strength concrete: An extreme learning approach. **Construction and Building Materials**, v. 208, p. 204–219, 2019.
- ALHADAS, M. F. S. Estudo da Influência do Agregado Graúdo de Diferentes Origens Mineralógicas nas Propriedades Mecânicas do Concreto. p. 126, 2008.
- ALVES, R. Resistência mecânica de concreto de cimento portland: correlação de ensaio à compressão axial com esclerometria. [s.l.] Centro Universitário UNIVATES, 2017.
- ANDOLFATO, R. P. Controle tecnológico básico do concreto. **Ilha Solteira: [s. N.]**, 2002.
- ARAÚJO, T. M. A. DE. Redes neurais incorporadas a métodos numéricos para solução de problemas de engenharia estrutural. 2015.
- ARAÚJO, S. DA S.; GUIMARÃES, G. N.; GEYER, A. L. B. Influence of the type of concrete, cylindrical specimen size and the type of laboratory in determining the compressive strength of concrete. **Revista Engenharia Civil - Universidade do Minho**, v. 52, p. 1–13, 2016.
- ARRUDA, A. M. D. Módulo de elasticidade de concretos produzidos com formações rochosas do triângulo mineiro. p. 166, 2013.
- ASSIS, D. M.; QUEIROGA, F. O. DA C. S.; MENDES, J. C. Utilização de rejeito de barragem de minério de ferro na fabricação de tijolos maciços. **Ágora**, v. 2, n. 1, p. 191–200, 2018.
- BARBOSA, I. L. S. Influencia dos agregados graúdos da Região de Goiânia no módulo de deformação tangente inicial do concreto. [s.l.] UNIVERSIDADE FEDERAL DE GOIÁS, 2009.
- BATISTA, J. L. F. Análise de Regressão Aplicada. p. 265, 2004.
- BECK, S. M. Efeitos nas propriedades mecânicas, elásticas e de deformação em concretos com

altos teores de escória e cinza volante. p. 141, 2009.

BEHNOOD, A.; GOLAFSHANI, E. M. Machine learning study of the mechanical properties of concretes containing waste foundry sand. **Construction and Building Materials**, v. 243, p. 118152, 2020.

BEHNOOD, A.; VERIAN, K. P.; MODIRI GHAREHVERAN, M. Evaluation of the splitting tensile strength in plain and steel fiber-reinforced concrete based on the compressive strength. **Construction and Building Materials**, v. 98, p. 519–529, 2015.

BEN CHAABENE, W.; FLAH, M.; NEHDI, M. L. Machine learning prediction of mechanical properties of concrete: Critical review. **Construction and Building Materials**, v. 260, p. 119889, 2020.

BENARCHID, Y. et al. Application of Quebec recycling guidelines to assess the use feasibility of waste rocks as construction aggregates. **Resources Policy**, v. 59, n. October 2017, p. 68–76, 2018.

BESSA, S. A. L. et al. Análises de argamassas de revestimento produzidas com rejeito de minério de ferro. **XVII Encontro Nacional de Tecnologia do Ambiente Construído**, n. August, p. 2765–2772, 2018.

BIAU, G. Analysis of a random forests model. **Journal of Machine Learning Research**, v. 13, p. 1063–1095, 2012.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer Science + Business Media, 2006.

BKA, M. A. R. et al. Recycled aggregates concrete compressive strength prediction using artificial neural networks (Anns). **Infrastructures**, v. 6, n. 2, p. 1–20, 2021.

BOCK, F. E. et al. A review of the application of machine learning and data mining approaches in continuum materials mechanics. **Frontiers in Materials**, v. 6, n. May, 2019.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: Teoria e Aplicações**. LTC, p. 1–10, 2000.

BREIMAN, L. Bagging predictors. **Risks**, v. 8, n. 3, p. 1–18, 1996.

BREIMAN, L. Random Forest. In: ROBERT E. SCHAPIRE (Ed.). **Machine Learning**. [s.l.] Machine Learning, 2001. v. 45p. 5–32.

CASTELLI, M.; VANNESCHI, L.; SILVA, S. Prediction of high performance concrete strength using Genetic Programming with geometric semantic genetic operators. **Expert Systems with Applications**, v. 40, n. 17, p. 6856–6862, 2013.

CASTRO, M. P. B. Dosagem de Concreto. **Dosagem de Concreto. Materiais Naturais e Artificiais**, 2017.

CHANG, C. C.; LIN, C. J. Training v-support vector regression: Theory and algorithms. **Neural Computation**, v. 14, n. 8, p. 1959–1977, 2002.

CHEIN, F. **Introdução aos modelos de regressão linear: um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas**. Brasília: Enap, 2019.

CHEN, B. T. et al. Estimation of exposed temperature for fire-damaged concrete using support vector machine. **Computational Materials Science**, v. 44, n. 3, p. 913–920, 2009.

CHEN, S.; ZHAO, Y.; BIE, Y. The prediction analysis of properties of recycled aggregate permeable concrete based on back-propagation neural network. **Journal of Cleaner Production**, v. 276, p. 124187, 2020.

CHENG, M. Y.; FIRDAUSI, P. M.; PRAYOGO, D. High-performance concrete compressive strength prediction using Genetic Weighted Pyramid Operation Tree (GW POT). **Engineering Applications of Artificial Intelligence**, v. 29, p. 104–113, 2014.

CHITHRA, S. et al. A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks. **Construction and Building Materials**, v. 114, p. 528–535, 2016.

CHOLLET, F. **Deep Learning With Python**. Shelter Island: Manning Publications Co, 2018.

CHOPRA, P. et al. Comparison of Machine Learning Techniques for the Prediction of Compressive Strength of Concrete. **Advances in Civil Engineering**, v. 2018, 2018.

CHOU, J. S. et al. Machine learning in concrete strength simulations: Multi-nation data analytics. **Construction and Building Materials**, v. 73, p. 771–780, 30 dez. 2014.

CIHAN, M. T. Prediction of Concrete Compressive Strength and Slump by Machine Learning Methods. **Advances in Civil Engineering**, v. 2019, 2019.

COLLINS, M.; SCHAPIRE, R. E.; SINGER, Y. Logistic regression, AdaBoost and Bregman distances. **Machine Learning**, v. 48, n. 1–3, p. 253–285, 2002.

CORREIA, F. M. Métodos Estatísticos e Redes Neurais Aplicados a Modelos Preditivos em Digestor Contínuo de Celulose Kraft de Eucalipto. p. 183, 2016.

COSTA, L. T. et al. Artigo Discente A produção de blocos de concreto confeccionados com rejeitos da construção civil para execução em alvenaria de vedação: a busca por alternativas sustentáveis. The production of concrete blocks made with tailings from the civil constructi. **Percorso Academico**, v. 7, n. 14, p. 504–518, 2017.

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**, v. 2021, 2021.

CUTLER, A. Trees and Random Forests. NIH 1R15AG037392-01. p. 92p., 2013.

CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. Ensemble Machine Learning. **Ensemble Machine Learning**, 2012.

DAHIYA, N.; SAINI, B.; CHALAK, H. D. Gradient boosting-based regression modelling for estimating the time period of the irregular precast concrete structural system with cross bracing. **Journal of Kinf Saud University - Engineering Sciences**, v. open acess, n. 1018–3639, p. 8, 2021.

DE CASTRO, A. L.; LIBORIO, J. B. L.; PANDOLFEG, V. C. A influência do tipo de cimento no desempenho de concretos avançados formulados a partir do método de dosagem

computacional. **Cerâmica**, v. 57, n. 341, p. 10–21, 2011.

DEROUSSEAU, M. A.; KASPRZYK, J. R.; SRUBAR, W. V. Computational design optimization of concrete mixtures: A review. **Cement and Concrete Research**, v. 109, n. April, p. 42–53, 2018.

DESHPANDE, N.; LONDHE, S.; KULKARNI, S. Modeling compressive strength of recycled aggregate concrete by Artificial Neural Network, Model Tree and Non-linear Regression. **International Journal of Sustainable Built Environment**, v. 3, n. 2, p. 187–198, 2014.

DIETTERICH, T. G. **Ensemble methods in machine learning**. In: Multiple Classifier Systems. MCS 2000. Lecture Notes in Computer Science. **Anais...** Springer, Berlin, Heidelberg, 2000

DUAN, J. et al. A novel artificial intelligence technique to predict compressive strength of recycled aggregate concrete using ICA-XGBoost model. **Engineering with Computers**, v. 37, n. 4, p. 3329–3346, 2021.

DUAN, Z. et al. Using neural networks to determine the significance of aggregate characteristics affecting the mechanical properties of recycled aggregate concrete. **Applied Sciences (Switzerland)**, v. 8, n. 11, 2018.

DUAN, Z. H.; KOU, S. C.; POON, C. S. Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. **Construction and Building Materials**, v. 40, p. 1200–1206, 2013.

EHLERS, R. S. *Introdução a Inferência Bayesiana*. 2003.

ERDAL, H. I. Two-level and hybrid ensembles of decision trees for high performance concrete compressive strength prediction. **Engineering Applications of Artificial Intelligence**, v. 26, n. 7, p. 1689–1697, 2013.

ERDAL, H. I.; KARAKURT, O.; NAMLI, E. High performance concrete compressive strength forecasting using ensemble models based on discrete wavelet transform. **Engineering Applications of Artificial Intelligence**, v. 26, n. 4, p. 1246–1254, 2013.

EVANGELISTA, A. C. J. **Avaliação da resistência do concreto usando diferentes ensaios destrutivos**. [s.l.] Universidade Federal do Rio de Janeiro, 2002.

FAROOQ, F. et al. A comparative study of random forest and genetic engineering programming for the prediction of compressive strength of high strength concrete (HSC). **Applied Sciences (Switzerland)**, v. 10, n. 20, p. 1–18, 2020.

FELIX, E. F.; CARRAZEDO, R.; POSSAN, E. Análise paramétrica da carbonatação em estruturas de concreto armado via Redes Neurais Artificiais. **Revista ALCONPAT**, v. 7, n. 3, p. 302–316, 2017.

FENG, D. C. et al. Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. **Construction and Building Materials**, v. 230, p. 117000, 10 jan. 2020.

FERNANDES, J. F.; BITTENCOURT, T. N.; HELENE, P. Concreto submetido a vibrações nas primeiras idades. **Revista IBRACON de Estruturas e Materiais**, v. 4, n. 4, p. 592–609, 2011.

FERRAZZO, S. T.; BRAGAGNOLO, L.; KORF, E. P. Caracterização tecnológica e reaproveitamento de rejeitos de magnetita em misturas asfálticas e concreto – uma revisão. **Revista Brasileira de Ciências Ambientais (Online)**, p. 1–21, 2020.

FERREIRA, M. H. Redes Neurais Artificiais: Princípios Básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016.

FILHO, D. B. F.; JÚNIOR, J. A. D. S. Desvendando os mistérios do coeficiente de correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115–146, 2009.

FRIEDMAN, J. H. Stochastic Gradient Boosting. **Computational Statistics & Data Analysis**, v. 38, p. 1189–1232, 2002.

FURTADO, M. I. V. **Redes Neurais Artificiais: Uma Abordagem Para Sala de Aula**. Ponta Grossa - PR: Atena, 2019.

GHOLAMPOUR, A. et al. Evaluation of mechanical properties of concretes containing coarse recycled concrete aggregates using multivariate adaptive regression splines (MARS), M5 model tree (M5Tree), and least squares support vector regression (LSSVR) models. **Neural Computing and Applications**, v. 32, n. 1, p. 295–308, 2020.

GIUSTOZZI, F.; SAUNIER, J.; ZANNI-MERK, C. Context Modeling for Industry 4.0: An Ontology-Based Proposal. **Procedia Computer Science**, v. 126, p. 675–684, 2018.

GOMES MARTINS, D. Influência Do Tamanho Do Corpo De Prova Nos Resultados De Ensaios De Módulo De Deformação E Resistência À Compressão E Suas Correlações Para Concretos Produzidos Em Goiânia -Go. **Dissertação apresentada ao Curso de Mestrado em Engenharia Civil da Universidade Federal de Goiás para obtenção do título de Mestre em Engenharia Civil**, p. 113, 2008.

GORSKI, R. K. S. Caracterização do concreto produzido com diferentes tipos e dimensões de agregados graúdos. p. 76, 2018.

GROVER, J. et al. Machine learning approach for multiple misbehavior detection in VANET. **Communications in Computer and Information Science**, v. 192 CCIS, n. PART 3, p. 644–653, 2011.

GUIMARÃES, O. C. **Avaliação Do Uso Da Água Magnetizada Na Produção De Concretos Em Centrais**. [s.l.] Universidade Federal de Minas Gerais, 2006.

HADZIMA-NYARKO, M. et al. Machine learning approaches for estimation of compressive strength of concrete. **European Physical Journal Plus**, v. 135, n. 8, 2020.

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

HAN, T. et al. An ensemble machine learning approach for prediction and optimization of modulus of elasticity of recycled aggregate concrete. **Construction and Building Materials**, v. 244, p. 118271, 2020.

HAYKIN, S. **Neural networks and learning machines**. [s.l.: s.n.]. v. 1–3

HELENE, P.; TUTIKIAN, B. F. Dosagem dos Concretos de Cimento Portland. **Concreto:**

**Ciência e Tecnologia**, n. 1927, p. 415, 2011.

HEPP, T. et al. Approaches to regularized regression - A comparison between gradient boosting and the lasso. **Methods of Information in Medicine**, v. 55, n. 5, p. 422–430, 2016.

HO, T. K. Random Decision Forests Tin Kam Ho Perceptron training. **Proceedings of 3rd International Conference on Document Analysis and Recognition**, v. 1, p. 278–282, 1995.

HOANG, N.-D.; PHAM, A.-D. Estimating Concrete Workability Based on Slump Test with Least Squares Support Vector Regression. **Journal of Construction Engineering**, v. 2016, p. 1–8, 2016.

HUANG, Y. et al. GBRTVis: online analysis of gradient boosting regression tree. **Journal of Visualization**, v. 22, n. 1, p. 125–140, 2019.

HUANG, Y. et al. Intelligent mixture design of steel fibre reinforced concrete using a support vector regression and firefly algorithm based multi-objective optimization model. **Construction and Building Materials**, v. 260, p. 120457, 2020.

IBRAM. Relatório anual de atividades: Janeiro a dezembro de 2019. p. 63, 2019.

IZBICKI; SANTOS. **Aprendizado de Máquina: uma abordagem estatística**. 1. ed. São Carlos: Câmara brasileira do Livro, 2020.

JAIN, A.; JHA, S. K.; MISRA, S. Modeling and Analysis of Concrete Slump Using Artificial Neural Networks. **Journal of Materials in Civil Engineering**, v. 20, n. 9, p. 628–633, 2008.

JALAL, M. et al. Experimental investigation and comparative machine-learning prediction of strength behavior of optimized recycled rubber concrete. **Construction and Building Materials**, v. 256, p. 119478, 2020.

JAMES, G. et al. **An Introduction to Statistical Learning with Applications in R**. New York: Springer Science + Business Media, 2013.

JHA, A. K. et al. Evaluation of Factors Affecting Compressive Strength of Concrete using Machine Learning. **Proceedings - 2020 Advanced Computing and Communication Technologies for High Performance Applications, ACCTHPA 2020**, p. 70–74, 2020.

KALMAN ŠIPOŠ, T.; MILIČEVIĆ, I.; SIDDIQUE, R. Model for mix design of brick aggregate concrete based on neural network modelling. **Construction and Building Materials**, v. 148, p. 757–769, 2017.

KE, X.; DUAN, Y. A Bayesian machine learning approach for inverse prediction of high-performance concrete ingredients with targeted performance. **Construction and Building Materials**, v. 270, n. xxxx, p. 121424, 2021.

KHADEMI, F. et al. Predicting strength of recycled aggregate concrete using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression. **International Journal of Sustainable Built Environment**, v. 5, n. 2, p. 355–369, 2016.

KITCHENHAM, B. et al. Robust Statistical Methods for Empirical Software Engineering. **Empirical Software Engineering**, v. 22, n. 2, p. 579–630, 2017.

KOPILER, A. A. et al. Redes Neurais Artificiais e suas aplicações no setor elétrico. v. 9, p. 27–33, 2019.

KORE, S. D.; VYAS, A. K. Impact of marble waste as coarse aggregate on properties of lean cement concrete. **Case Studies in Construction Materials**, v. 4, p. 85–92, 1 jun. 2016.

KORE, S. D.; VYAS, A. K.; SYED, S. A. A brief review on sustainable utilisation of marble waste in concrete. **International Journal of Sustainable Engineering**, v. 13, n. 4, p. 264–279, 2020.

KOSSOFF, D. et al. Mine tailings dams: Characteristics, failure, environmental impacts, and remediation. **Applied Geochemistry**, v. 51, n. December, p. 229–245, 2014.

KOYA, B. P. et al. Comparative analysis of different machine learning algorithms to predict mechanical properties of concrete. **Mechanics of Advanced Materials and Structures**, v. 0, n. 0, p. 1–18, 2021.

KUMMER, L. M. Resistência à compressão e módulo de elasticidade dos concretos de uma central dosadora de concreto de Lajeado/RS. p. 67, 2016.

LAKE, B. M. et al. Building machines that learn and think like people. **Behavioral and Brain Sciences**, v. 40, n. 2017, 2017.

LATIF, S. D. **Concrete compressive strength prediction modeling utilizing deep learning long short-term memory algorithm for a sustainable environment** *Environmental Science and Pollution Research*, 2021.

LIAKOS, K. G. et al. Machine learning in agriculture: A review. **Sensors (Switzerland)**, v. 18, n. 8, p. 1–29, 2018.

LOPES, D. F. Análise técnica da substituição parcial e total do agregado graúdo por estéril escalpado de mineração destinado à fabricação de concreto. p. 132, 2018.

LOPES, R. F. **Modelagem matemática computacional de com- pósitos de argamassa leve reforçada com fibras de piaçava**. [s.l.] Universidade Estadual de Santa Cruz, 2012.

LORENZI, A. Aplicação de redes neurais artificiais para estimativa da resistência à compressão do concreto a partir da velocidade de propagação do pulso ultra-sônico. **2009. 196 f. Tese (doutorado) - Universidade Federal do Rio Grande do Sul. Porto Alegre, RS**, n. 51, p. 196, 2009a.

LORENZI, A. **Aplicação de redes neurais artificiais para estimativa da resistência à compressão do concreto a partir da velocidade de propagação do pulso ultra-sônico** **2009. 196 f. Tese (doutorado) - Universidade Federal do Rio Grande do Sul. Porto Alegre, RS**, 2009b.

LORENZI, A. et al. Artificial neural networks application to predict bond steel-concrete in pull-out tests. **Revista IBRACON de Estruturas e Materiais**, v. 10, n. 5, p. 1051–1074, 2017.

LORENZI, A.; SILVA FILHO, L. C. P. DA; CAMPAGNOLO, J. L. Development of artificial neural networks for interpreting ultrasonic pulse velocity tests in concrete. v. 4, n. 5, 2011.

LOUPPE, G.; GEURTS, P. Ensembles on Random Patches. In: FLACH P.A., DE BIE T., C. N. (Ed.). **(EDS) Machine Learning and Knowledge Discovery in Databases. ECML PKDD 2012. Lecture Notes in Computer Science**. [s.l.] Springer, Berlin, Heidelberg., 2012. v. 7523p. 346–361.

LUCENA DE SOUSA, D.; GONÇALVES DE OLIVEIRA, M.; SÉRGIO LIMA SOUZA, P. Análise comparativa entre dois tipos de agregados utilizados em obras de pequeno e médio porte no município de Tucuruí - PA [Comparative analysis between two types of aggregates used in small and middle size works in the municipality of Tucuruí - PA]. **REEC - Revista Eletrônica de Engenharia Civil**, v. 14, n. 2, p. 107–119, 2018.

MA, H. et al. Estimating the Compressive Strength of Cement-Based Materials with Mining Waste Using Support Vector Machine, Decision Tree, and Random Forest Models. **Advances in Civil Engineering**, v. 2021, 2021.

MAGHFOURI, M. et al. Appropriate drying shrinkage prediction models for lightweight concrete containing coarse agro-waste aggregate. **Journal of Building Engineering**, v. 29, n. June 2019, p. 101148, 2020.

MAIA, A. T.; IAROSZINSKI NETO, A. Quais as principais características organizacionais das empresas dos diferentes segmentos da construção civil? **Ambiente Construído**, v. 16, n. 3, p. 197–215, 2016.

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

MARTINI, G. Predictive Modelling of Asphalt Concrete Functional Properties Using Multiple Linear Regression and Gradient Boosting. n. October, 2019.

MATA, J. Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. **Engineering Structures**, v. 33, n. 3, p. 903–910, 2011.

MAYORCA, F. D. O. **Redes neuronales artificiales en la estimación de la resistencia a la compresión del concreto para la Provincia de Huancayo**. [s.l.] Universidad Nacional Del Centro Del Perú, 2020.

MEDEIROS-JUNIOR, M. G. L. A. O. R. A. **Acompanhamento da influência da diferença do método de adensamento -manul ou mecânico - na resistência à compressão de corpos de prova de concreto até 91 dias**. CONPAT - Lisboa. **Anais...Lisboa: 2015**

METHA, P. K.; MONTEIRO, P. J. M. **Microestrutura, propriedades e materiais. Microestrutura do Concreto**, 2008. Disponível em: <[https://tuxdoc.com/download/concreto-microestrutura-propriedades-e-materias-mehta-e-paulo-monteiro-2-ed-2008\\_pdf](https://tuxdoc.com/download/concreto-microestrutura-propriedades-e-materias-mehta-e-paulo-monteiro-2-ed-2008_pdf)>

MILLER, S. A.; HORVATH, A.; MONTEIRO, P. J. M. Impacts of booming concrete production on water resources worldwide. **Nature Sustainability**, v. 1, n. 1, p. 69–76, 2018.

MOHAMMED, A. et al. Soft computing techniques: Systematic multiscale models to predict the compressive strength of HVFA concrete based on mix proportions and curing times. **Journal of Building Engineering**, v. 33, p. 101851, 2021.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to linear regression analysis**. 5. ed. Canada: John Wiley & Sons Inc., 2012.

MONTGOMERY, DOUGLAS C.; RUNGER, G. C.; MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and probability for Engineers**. 6. ed. USA: John Wiley & Sons Inc., 2014. v. 19

- NADERPOUR, H. et al. Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. **Composite Structures**, v. 215, n. February, p. 69–84, 2019.
- NATEKIN, A.; KNOLL, A. Gradient boosting machines, a tutorial. **Frontiers in Neurorobotics**, v. 7, n. DEC, 2013.
- NEELAKANTA, P. S.; DE GROFF, D. F. **Neural network modeling: Statistical mechanics and cybernetic perspectives**. [s.l.: s.n.].
- NEHDI, M.; EL CHABIB, H.; EL NAGGAR, M. H. Predicting performance of self-compacting concrete mixtures using artificial neural networks. **ACI Materials Journal**, v. 98, n. 5, p. 394–401, 2001.
- NETO, A. A. DE M.; HELENE, P. R. DO L. Módulo de Elasticidade: Dosagem e Avaliação de Modelos de Previsão do Módulo de Elasticidade de Concretos Resumo 1 Introdução O módulo de elasticidade pode ser definido como sendo a relação entre a tensão. n. 1, 2002.
- NETO, B. B. P.; OLIVEIRA, D. R. C.; RAMOS, D. Efeitos do tipo, tamanho e teor de agregado graúdo no módulo de deformação do concreto de alta resistência. **Revista Materia**, v. 16, n. 2, p. 690–702, 2011.
- NGUYEN-SY, T. et al. Predicting the compressive strength of concrete from its compositions and age using the extreme gradient boosting method. **Construction and Building Materials**, v. 260, p. 119757, 2020.
- NGUYEN, H. et al. Efficient machine learning models for prediction of concrete strengths. **Construction and Building Materials**, v. 266, p. 120950, 2021a.
- NGUYEN, T. D. et al. A success history-based adaptive differential evolution optimized support vector regression for estimating plastic viscosity of fresh concrete. **Engineering with Computers**, v. 37, n. 2, p. 1485–1498, 2021b.
- NUNES, F. W. DA G. Resistência e módulo de elasticidade de concretos usados no Rio de Janeiro. p. 126, 2005.
- NUNEZ, I.; MARANI, A.; NEHDI, M. L. Mixture optimization of recycled aggregate concrete using hybrid machine learning model. **Materials**, v. 13, n. 19, p. 1–24, 2020.
- NUNEZ, I.; NEHDI, M. L. Machine learning prediction of carbonation depth in recycled aggregate concrete incorporating SCMs. **Construction and Building Materials**, v. 287, p. 123027, 2021.
- OLALUSI, O. B.; SPYRIDIS, P. Machine learning-based models for the concrete breakout capacity prediction of single anchors in shear. **Advances in Engineering Software**, v. 147, n. May, p. 102832, 2020.
- OLIVEIRA FILHO, A. G. **Análise comparativa da estimativa do índice de compressão de argilas por redes neurais artificiais e correlações empíricas**. [s.l.] Universidade Federal do Espírito Santo, Centro Tecnológico, 2019.
- OMRAN, B. A.; CHEN, Q.; JIN, R. Comparison of Data Mining Techniques for Predicting Compressive Strength of Environmentally Friendly Concrete. **Journal of Computing in Civil Engineering**, v. 30, n. 6, p. 04016029, 2016.

PACHECO, J. N. et al. Probabilistic conversion of the compressive strength of cubes to cylinders of natural and recycled aggregate concrete specimens. **Materials**, v. 12, n. 2, 2019.

PACHECO, R. F. R. **Análise do módulo de elasticidade e resistência à compressão de concretos produzidos em centrais na grande vitória. Experimentos e estatística.** [s.l.] Universidade Federal do Espírito Santo, 2006.

PARK, J. Y.; YOON, Y. G.; OH, T. K. Prediction of concrete strength with P-, S-, R-wave velocities by support vector machine (SVM) and artificial neural network (ANN). **Applied Sciences (Switzerland)**, v. 9, n. 19, 2019.

PEDROSO, C. L. Compósitos à base de rejeito do minério de ferro, resíduo de concreto, resíduos da produção de celulose e resíduo da produção da cal. 2020.

PESTANA, M. S. **Utilização de redes neurais artificiais para avaliar o efeito da tensão média na fadiga do cabo CAL 1055 MCM.** [s.l.] Universidade de Brasília, 2017.

PHAM, A.-D.; HOANG, N.-D.; NGUYEN, Q.-T. Predicting Compressive Strength of High-Performance Concrete Using Metaheuristic-Optimized Least Squares Support Vector Regression. **Journal of Computing in Civil Engineering**, v. 30, n. 3, p. 06015002, 2016.

PINO, F. A. A Questão Da Não Normalidade: uma revisão. **Rev. de Economia Agrícola**, v. 61, n. 2, p. 17–33, 2014.

R. A. MEDEIROS-JUNIOR, M. G. LIMA, M. H. F. MEDEIROS, L. V. R. Investigação da resistência à compressão e da resistividade elétrica de concretos com diferentes tipos de cimento. **Alconpat**, v. 2, n. Maio-Agosto, p. 116–132, 2014.

RAJESHWARI, R.; MANDAL, S. Prediction of compressive strength of high-volume fly ash concrete using artificial neural network. **Lecture Notes in Civil Engineering**, v. 25, p. 471–483, 2019.

RATHAKRISHNAN, V.; BEDDU, S.; AHMED, A. N. Comparison Studies Between Machine Learning Optimisation Technique on Predicting Concrete Compressive Strength. 2021.

REIS, M. J.; COLLARES, E. G.; REIS, F. M. D. Technological assessment of tailings from quartzite mining sites in Alpinópolis (Minas Gerais–Brazil) as aggregates in concrete block paving (CBP). **Bulletin of Engineering Geology and the Environment**, v. 77, n. 4, p. 1623–1637, 2018.

REIS, R. J. P. **Influência de areias artificiais de rochas britadas na estrutura e nas propriedades de concretos de cimento Portland.** [s.l.] Universidade federal de Minas Gerais, 2004.

REZAIEE-PAJAND, M. et al. Propose new implement models to determine the compressive, tensile and flexural strengths of recycled coarse aggregate concrete via imperialist competitive algorithm. **Journal of Building Engineering**, v. 40, n. November 2020, p. 102337, 2021.

RODRIGUES, R.; DE BRITO, J.; SARDINHA, M. Mechanical properties of structural concrete containing very fine aggregates from marble cutting sludge. **Construction and Building Materials**, v. 77, p. 349–356, 2015.

RUSCHI, M. et al. A influência do tipo de cimento, da resistência característica e da vida útil na ecoeficiência do concreto a partir da Avaliação do Ciclo de Vida Resumo A indústria da

construção e o uso do ambiente construído são responsáveis por uma porção considerável. n. 1, p. 1–16, 2009.

SADEGHIPOUR CHAHNASIR, E. et al. Application of support vector machine with firefly algorithm for investigation of the factors affecting the shear strength of angle shear connectors. **Smart Structures and Systems**, v. 22, n. 4, p. 413–424, 2018.

SAHA, P.; DEBNATH, P.; THOMAS, P. Prediction of fresh and hardened properties of self-compacting concrete using support vector regression approach. **Neural Computing and Applications**, v. 32, n. 12, p. 7995–8010, 2020.

SALEHI, H.; BURGUEÑO, R. Emerging artificial intelligence methods in structural engineering. **Engineering Structures**, v. 171, n. May, p. 170–189, 2018.

SALGADO, L. DE M. **Blocos de concreto para pavimentação produzidos com rejeito de mineração e cinzas de bagaço de cana de açúcar**. [s.l.] Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2018.

SALIMBAHRAMI, S. R.; SHAKERI, R. Experimental investigation and comparative machine-learning prediction of compressive strength of recycled aggregate concrete. **Soft Computing**, v. 25, n. 2, p. 919–932, 2021.

SAMPAIO, G.; CARLOS, M. M. Análise Da Influência Da Litologia Do Agregado Graúdo Nas Propriedades De Resistência À Compressão E Resistividade Elétrica Do Concreto. **Revista CONSTRUINDO**, v. 10, p. 10–18, 2018.

SANTOS, D. D.; GODINHO, D. S. S. **Análise Da Evolução Das Propriedades Mecânicas Do Concreto Ao Longo Do Tempo**. [s.l.] Universidade do Extremo Sul Catarinense, 2017.

SANTOS, A. C. DOS et al. Estudo comparativo entre valores teóricos e resultados experimentais de módulo de elasticidade de concretos produzidos com diferentes tipos de agregado graúdo. **Ambiente Construído**, v. 17, n. 3, p. 281–294, 2017.

SANTOS, G. C. Algoritmos De Machine Learning Para Previsão De Ações Da B3. p. 94, 2020.

SAVARGIV, M.; MASOUMI, B.; KEYVANPOUR, M. R. A new random forest algorithm based on learning automata. **Computational Intelligence and Neuroscience**, v. 2021, 2021.

SCHAPIRE, R. E. A Short Introduction to Boosting. **Society**, v. 14, n. 5, p. 771–780, 2009.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding machine learning: From theory to algorithms**. Cambridge University Press. v. 9781107057, 2014. Disponível em: <http://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning>

SHARIATI, M. et al. A novel hybrid extreme learning machine–grey wolf optimizer (ELM-GWO) model to predict compressive strength of concrete with partial replacements for cement. **Engineering with Computers**, 2020.

SILVEIRA, M. D. **Utilização de resíduos de mineração na construção civil**. [s.l.] Universidade Federal de Minas Gerais, 2015.

SIMÃO, D. W. DA G. Análise e dimensionamento de vigas de concreto armado com aberturas na alma. 2014.

SINGH, M. et al. A study on environmental and economic impacts of using waste marble

powder in concrete. **Journal of Building Engineering**, v. 13, p. 87–95, 2017.

SOLLERO, M. B. DE S. **Faculdade de Engenharia Civil, Arquitetura e Urbanismo 2021**. [s.l.] Universidade Estadual de Campinas, 2019.

SOLOMATINE, D. P.; SHRESTHA, D. L. AdaBoost.RT: A boosting algorithm for regression problems. **IEEE International Conference on Neural Networks - Conference Proceedings**, v. 2, p. 1163–1168, 2004.

SONG, H. et al. Predicting the compressive strength of concrete with fly ash admixture using machine learning algorithms. **Construction and Building Materials**, v. 308, p. 125021, 2021.

SOUZA, A. A. A. **Influência Do Tipo De Agregado Nas Propriedades Mecânicas Do Concreto Submetido Ao Fogo**. [s.l.] Universidade Estadual de Campinas, 2005.

SOUZA, R. M. DE; MAGALHÃES, R. R.; CAMPOS, A. T. Modelo neuro-fuzzy para predição do aporte de energia de diferentes dosagens de concreto em edificações. **Ambiente Construído**, v. 21, n. 2, p. 295–309, 2021.

TEIXEIRA, R. F. et al. Análise Estatística Da Resistência A Compressão Do Concreto. p. 635–643, 2015.

THOMAS, J. et al. Gradient boosting for distributional regression: faster tuning and improved variable selection via noncyclical updates. **Statistics and Computing**, v. 28, n. 3, p. 673–687, 2018.

CHEN, T.; GUESTRIN, C. **XGBoost: A Scalable Tree Boosting System**. KDD16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. **Anais**: San Francisco: 2016. Disponível em: <<https://dl.acm.org/doi/10.1145/2939672.2939785>>

TIANQI CHEN; TONG HE; xgboost: Extreme Gradient Boosting. **R Lecture**, n. 2016, p. 1–84, 2014.

TINOCO, J.; GOMES CORREIA, A.; CORTEZ, P. Support vector machines applied to uniaxial compressive strength prediction of jet grouting columns. **Computers and Geotechnics**, v. 55, p. 132–140, 2014.

TIPPING, M. E. Sparse Bayesian Learning and the Relevance Vector Machine. **Journal of Machine Learning Research**, v. 1, n. 3, p. 211–244, 2001.

TOGHROLI, A. et al. Potential of soft computing approach for evaluating the factors affecting the capacity of steel–concrete composite beam. **Journal of Intelligent Manufacturing**, v. 29, n. 8, p. 1793–1801, 2018.

TORALLES, B. M.; COUTO, A. F.; NOGUEIRA, G. S. F.; SANDOVAL, G. F. B.; ALVES, G. P.; SOUZA, I. C. R. S. P. Estudo Comparativo De Diferentes Métodos De Dosagem De Concretos Convencionais. **Revista De Engenharia E Tecnologia**, v. 10, n. 1, p. 184–198, 2018.

VARGAS, V. H. Estudo Experimental Da Influência Do Agregado Graúdo De Diferentes Origens Mineralógicas Nas Propriedades Mecânicas Do Concreto. Unesc. n. 2008, p. 1–15, 2017.

VILELA, M. N. **Análise Do Módulo De Elasticidade Do Concreto Para Diferentes Origens Dos Agregados Graúdos Da Região De Anápolis/GO.** [s.l.] UniEvangélica, 2019.

VITOR, P.; SOUZA, C. Avaliação De Técnicas De Regularização Aplicadas As Redes Neurais Nebulosas. Belo Horizonte Ano 2015. n. October 2015, 2018.

ALVARENGA JÚNIOR, W. J. Métodos De Otimização Hiperparamétrica: Um Estudo Comparativo Utilizando Árvores De Decisão E Florestas Aleatórias Na Classificação Binária. p. 82, 2018.

WAN, Z.; XU, Y.; SAVIJA, B. On the Use of Machine Learning Models for Prediction of Compressive Strength of Concrete: Influence of Dimensionality Reduction on the Model Performance. **Materials**, v. 14, n. 713, p. 1–21, 2021.

WANG, Y.; GEEM, Z. W.; NAGAI, K. Bond strength assessment of concrete-corroded rebar interface using artificial neural network. **Applied Sciences (Switzerland)**, v. 10, n. 14, 2020.

XIN YAN; SU, X. G. **Linear Regression Analysis: theory and computing.** New Jersey: World Scientific Publishing Co, 2009. v. 22

XU, J. et al. Comprehensive machine learning-based model for predicting compressive strength of ready-mix concrete. **Materials**, v. 14, n. 5, p. 1–18, 2021.

YAN, K.; SHI, C. Prediction of elastic modulus of normal and high strength concrete by support vector machine. **Construction and Building Materials**, v. 24, n. 8, p. 1479–1485, 2010.

YANG, H. Y.; DONG, Y. F. Modelling concrete strength using support vector machines. **Applied Mechanics and Materials**, v. 438–439, p. 170–173, 2013.

YASEEN, Z. M. et al. Predicting compressive strength of lightweight foamed concrete using extreme learning machine model. **Advances in Engineering Software**, v. 115, p. 112–125, 1 jan. 2018.

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

YOUNG, B. A. et al. Can the compressive strength of concrete be estimated from knowledge of the mixture proportions? New insights from statistical analysis and machine learning methods. **Cement and Concrete Research**, v. 115, n. July, p. 379–388, 2019.

YU, Y. et al. A novel optimised self-learning method for compressive strength prediction of high performance concrete. **Construction and Building Materials**, v. 184, p. 229–247, 2018.

ZANELLA, A. K.; MARIA, S. Análise das propriedades mecânicas de concretos para pavimentação empregando diferentes processos de cura. 2014.

ZANGESKI, D. D. S. O. et al. Estudo Comparativo Entre a Resistência à Compressão do Concreto com Agregado Convencional Calcário e com Agregados Recicláveis. **Ensaio e Ciência: C. Biológicas, Agrárias e da Saúde**, v. 21, n. 2, p. 64, 2017.

ZHANG, J.; LI, D.; WANG, Y. Toward intelligent construction: Prediction of mechanical properties of manufactured-sand concrete using tree-based models. **Journal of Cleaner Production**, v. 258, p. 120665, 2020.

ZHANG, Q. et al. Genetic programming in civil engineering: advent, applications and future

trends. **Artificial Intelligence Review**, v. 54, n. 3, p. 1863–1885, 2021.

ZHOU, C.; CHEN, Z. Mechanical properties of recycled concrete made with different types of coarse aggregate. **Construction and Building Materials**, v. 134, p. 497–506, 2017.

ZHU, Y. et al. Valorization of calcined coal gangue as coarse aggregate in concrete. **Cement and Concrete Composites**, v. 121, n. February, p. 104057, 2021.

ZIOLKOWSKI, P.; NIEDOSTATKIEWICZ, M. Machine learning techniques in concrete mix design. **Materials**, v. 12, n. 8, 2019.

## APÊNDICES

### APÊNDICE A – Resultados dos Ensaio de Resistência Mecânica

**Tabela A. 1 - Resultados médios do ensaio de resistência à compressão dos concretos produzidos**

CONCRETOS	RELAÇÃO A/C		RESISTÊNCIA À COMPRESSÃO (MPa)			
			7 dias	14 dias	28 dias	56 dias
0 %	0,5	$f_{ck}$	18,64	20,58	25,18	25,16
		$D_p$	1,10	2,31	2,48	1,34
25 %	0,5	$f_{ck}$	19,79	21,70	25,62	26,08
		$D_p$	1,19	2,34	1,75	0,92
50 %	0,5	$f_{ck}$	19,96	21,38	25,80	25,22
		$D_p$	0,68	2,12	1,43	1,22
75 %	0,5	$f_{ck}$	20,74	22,43	26,02	26,01
		$D_p$	1,08	1,74	1,45	1,57
100 %	0,5	$f_{ck}$	20,17	22,40	25,39	25,60
		$D_p$	1,35	1,56	1,66	0,99
0 %	0,7	$f_{ck}$	11,08	13,42	14,10	14,54
		$D_p$	0,89	0,24	0,69	0,25
50 %	0,7	$f_{ck}$	12,33	14,51	16,02	16,18
		$D_p$	0,34	0,76	0,75	0,48
100 %	0,7	$f_{ck}$	14,26	15,21	16,11	16,78
		$D_p$	0,32	0,97	0,72	0,95

Fonte: Adaptado de Lopes (2018)


**Tabela A. 2 - Resultados médios do ensaio de resistência à tração dos concretos produzidos**

CONCRETOS	RELAÇÃO A/C		RESISTÊNCIA À TRAÇÃO (MPa)			
			7 dias	14 dias	28 dias	56 dias
0 %	0,5	$f_{ct}$	2,17	2,33	2,85	2,99
		$D_p$	0,10	0,26	0,24	0,26
25 %	0,5	$f_{ct}$	2,20	2,37	3,01	3,15
		$D_p$	0,07	0,27	0,19	0,19
50 %	0,5	$f_{ct}$	2,19	2,35	3,00	3,06
		$D_p$	0,18	0,18	0,29	0,33
75 %	0,5	$f_{ct}$	2,26	2,41	3,07	3,14
		$D_p$	0,14	0,11	0,12	0,26
100 %	0,5	$f_{ct}$	2,28	2,39	3,02	3,02
		$D_p$	0,39	0,45	0,20	0,31
0 %	0,7	$f_{ct}$	1,33	1,48	1,65	1,72
		$D_p$	0,06	0,09	0,03	0,07
50 %	0,7	$f_{ct}$	1,33	1,55	1,94	2,05
		$D_p$	0,06	0,03	0,11	0,12
100 %	0,7	$f_{ct}$	1,38	1,50	1,96	2,08
		$D_p$	0,03	0,08	0,27	0,14

Fonte: Adaptado de Lopes (2018)

## APÊNDICE B – Correlograma do *Data Set 2*

Figura B. 1 – Gráfico de correlação das variáveis do *Data Set 2*



## APÊNDICE C - Resultados dos Modelos de Predição da Resistência Mecânica dos Concretos

Tabela C. 1 – Resultados da predição da resistência  $f_{ck}$  do *data set 1*

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,950908	0,006902	0,064881	0,083080
2	Linear Múltipla	0,935575	0,910584	0,007298	0,068842	0,085430
3	Ridge	0,853121	0,854222	0,011899	0,092639	0,109080
4	Bayesiana	0,932073	0,909053	0,007423	0,070558	0,086158
5	Lasso	0,876246	0,848890	3,101167	1,390329	1,761013
6	Polinomial Grau 2	0,960163	0,907612	0,007541	0,064519	0,086838
7	Polinomial Grau 3	0,962956	0,918458	0,006656	0,061110	0,081581
8	Polinomial Grau 4	0,966649	0,923029	0,006282	0,063547	0,079262
9	SVM	0,916935	0,909286	0,007404	0,071748	0,086047
10	KNN	0,951182	0,909133	1,864833	1,095747	1,365589
11	Árvore de Decisão	0,969242	0,916938	0,006780	0,069490	0,082338
12	Árvore de Decisão 2	0,962650	0,922574	0,006320	0,065624	0,079496
13	AdaBoost	0,957208	0,913092	0,007094	0,067152	0,084223
14	Floresta Aleatória	0,968737	0,925939	0,006045	0,064086	0,077749
15	Floresta Aleatória 2	0,966423	0,926234	0,006021	0,064038	0,077594
16	Gradient Boosting	0,968598	0,921824	0,006381	0,066159	0,079880
17	Gradient Boosting 2	0,966016	0,925468	0,006083	0,063663	0,077996
18	XGBoosting	0,967879	0,921061	0,006443	0,065103	0,080269
19	XGBoosting 2	0,960382	0,924644	0,006151	0,065042	0,078426
20	RNA	0,845530	0,939146	1,550730	1,103138	1,245283

Tabela C. 2 – Resultados da predição da resistência  $f_{ct}$  do *data set 1*

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,950591	0,011488	0,082083	0,107184
2	Linear Múltipla	0,942481	0,965966	0,007221	0,069409	0,084978
3	Ridge	0,848212	0,904267	0,020312	0,126046	0,142522
4	Bayesiana	0,940015	0,966319	0,007146	0,066702	0,084536
5	Lasso	0,897094	0,936165	0,331052	0,490578	0,575371
6	Polinomial Grau 2	0,947943	0,958232	0,008862	0,069597	0,094139
7	Polinomial Grau 3	0,957919	0,947177	0,011208	0,081583	0,105867
8	Polinomial Grau 4	0,960409	0,941934	0,012320	0,085087	0,110997
9	SVM	0,917994	0,962135	0,008034	0,075336	0,089633
10	KNN	0,939396	0,951026	0,253982	0,371264	0,503967
11	Árvore de Decisão	0,960654	0,941423	0,012429	0,086976	0,111484
12	Árvore de Decisão 2	0,958052	0,955056	0,009536	0,070482	0,097653
13	AdaBoost	0,952829	0,944724	0,011728	0,086174	0,108297
14	Floresta Aleatória	0,960329	0,950527	0,010497	0,080260	0,102455
15	Floresta Aleatória 2	0,958969	0,953724	0,009819	0,076793	0,099089
16	Gradient Boosting	0,960562	0,944206	0,011838	0,085658	0,108804
17	Gradient Boosting 2	0,955284	0,962365	0,007985	0,070910	0,089360
18	XGBoosting	0,959871	0,949871	0,010636	0,081486	0,103132
19	XGBoosting 2	0,953503	0,961297	0,008212	0,070934	0,090619
20	RNA	0,900991	0,903293	0,554107	0,536430	0,744383

Tabela C. 3 – Resultados da predição da resistência  $f_{ck}$  do *data set 2*

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,676892	19,583916	3,485824	4,425372
2	Linear Múltipla	0,667113	0,684273	18,878511	3,477280	4,344941
3	Ridge	0,666922	0,684288	18,877605	3,483477	4,344837
4	Bayesiana	0,666464	0,683928	18,899188	3,489305	4,347320
5	Lasso	0,621674	0,643773	21,300183	3,670353	4,615212
6	Polinomial Grau 2	0,863612	-2,01e+18	1,20e+20	8,10e+08	1,09e+10
7	Polinomial Grau 3	0,929108	-4,21e+17	2,52e+19	4,31e+08	5,02e+09
8	Polinomial Grau 4	0,940949	-3,93e+15	2,35e+17	4,73e+07	4,84e+08
9	SVM	0,647951	0,665130	20,02312	3,533798	4,474721
10	KNN	0,872397	0,784204	12,903229	2,473179	3,592106
11	Árvore de Decisão	0,941026	0,850383	8,946160	1,987975	2,991013
12	Árvore de Decisão 2	0,837485	0,788798	12,628537	2,582630	3,553665
13	AdaBoost	0,598981	0,610269	23,303458	3,944025	4,827366
14	Floresta Aleatória	0,930952	0,861604	8,275171	1,979275	2,876659
15	Floresta Aleatória 2	0,853055	0,805584	11,624871	2,544092	3,409526
16	Gradient Boosting	0,874674	0,850952	8,912110	2,248358	2,985315
17	Gradient Boosting 2	0,934726	0,869459	7,805516	1,918397	2,793835
18	XGBoosting	0,868370	0,843996	9,328073	2,302183	3,054189
19	XGBoosting 2	0,932033	0,866548	7,979588	1,957726	2,824816
20	RNA	0,845034	0,803273	21,687695	3,407170	4,657005

Tabela C. 4 – Resultados da predição da resistência  $f_{ck}$  do *data set 2*, dados completos sem *outlier*

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,657365	22,177494	3,494787	4,709299
2	Linear Múltipla	0,663457	0,615505	21,764992	3,643432	4,665297
3	Ridge	0,663479	0,625113	21,221081	3,604601	4,606634
4	Bayesiana	0,661051	0,627912	21,062637	3,587300	4,589405
5	Lasso	0,604880	0,603320	22,454693	3,764663	4,738638
6	Polinomial Grau 2	0,814046	-1,48e+21	8,39e+22	4,17e+10	2,89e+11
7	Polinomial Grau 3	0,92245	-1,01e+18	5,72e+19	1,57e+09	7,56e+9
8	Polinomial Grau 4	0,922757	-9,04e+16	5,11e+18	5,58e+08	2,26e+9
9	SVM	0,629212	0,612461	21,937236	3,543944	4,68372
10	KNN	0,788282	0,667598	18,816150	2,961107	4,33775
11	Árvore de Decisão	0,922758	0,7165826	16,043303	2,794193	4,005409
12	Árvore de Decisão 2	0,8033756	0,685698	17,7915562	3,2033598	4,218003
13	AdaBoost	0,657573	0,627673	21,076134	3,666137	4,590875
14	Floresta Aleatória	0,903579	0,826375	9,828307	2,340316	3,135013
15	Floresta Aleatória 2	0,840054	0,788931	11,947884	2,610908	3,456571
16	Gradient Boosting	0,877989	0,833770	9,409718	2,378678	3,067526
17	Gradient Boosting 2	0,912872	0,815762	10,429037	2,417325	3,229402
18	XGBoosting	0,860510	0,824858	9,914164	2,441700	3,148676
19	XGBoosting 2	0,916763	0,809646	10,775280	2,402670	3,282572
20	RNA	0,838772	0,802806	18,959090	3,278412	4,354204

Tabela C. 5 – Resultados da predição da resistência  $f_{ck}$  do grupo A

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	65,77903	22,10092	3,487588	4,701161
2	Linear Múltipla	0,663187	61,61620	23,04559	3,755392	4,800582
3	Ridge	0,662561	0,6175781	22,96056	3,745207	4,791718
4	Bayesiana	0,660188	0,6174289	22,96952	3,734332	4,792653
5	Lasso	0,603540	0,5794764	25,24819	4,032445	5,024758
6	Polinomial Grau 2	0,776917	-4,88e+19	2,93e+21	4,56e+09	5,41e+10
7	Polinomial Grau 3	0,918164	-1,05e+17	6,31e+18	3,55e+08	2,51e+09
8	Polinomial Grau 4	0,919314	-2,70e+02	1,63e+04	18,12284	1,27e+02
9	SVM	0,625432	0,597411	24,171370	3,733705	4,916439
10	KNN	0,778277	0,713807	17,182957	2,903441	4,145233
11	Árvore de Decisão	0,919314	0,781192	13,137199	2,436600	3,624527
12	Árvore de Decisão 2	0,789841	0,732034	16,088628	2,967017	4,011063
13	AdaBoost	0,642451	0,597946	24,139272	3,829255	4,913173
14	Floresta Aleatória	0,898922	0,833243	10,012065	2,239993	3,164185
15	Floresta Aleatória 2	0,830472	0,797967	12,130018	2,647389	3,482818
16	Gradient Boosting	0,872989	0,833639	9,988291	2,372051	3,160426
17	Gradient Boosting 2	0,913929	0,834005	9,966274	2,237367	3,156941
18	XGBoosting	0,863295	0,836471	9,818257	2,410436	3,133410
19	XGBoosting 2	0,912181	0,807652	11,548538	2,343550	3,398314
20	RNA	0,792106	0,726580	26,186137	3,809736	5,117239

Tabela C. 6 – Resultados da predição da resistência  $f_{ck}$  do grupo A sem outlier

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,657365	22,177494	3,494787	4,709299
2	Linear Múltipla	0,663457	0,615505	21,764992	3,643432	4,665297
3	Ridge	0,663479	0,625113	21,221081	3,604601	4,606634
4	Bayesiana	0,661051	0,627912	21,062637	3,587300	4,589405
5	Lasso	0,604880	0,603320	22,454693	3,764663	4,738638
6	Polinomial Grau 2	0,814046	-1,48e+21	8,39e+22	4,17e+10	2,89e+11
7	Polinomial Grau 3	0,922454	-1,01e+18	5,72e+19	1,57e+09	7,56e+09
8	Polinomial Grau 4	0,922757	-9,04e+16	5,11e+18	5,58e+08	2,26e+09
9	SVM	0,629212	0,612461	21,937236	3,543945	4,683720
10	KNN	0,788282	0,667598	18,816150	2,961108	4,337759
11	Árvore de Decisão	0,922758	0,730288	15,267441	2,744507	3,907357
12	Árvore de Decisão 2	0,803375	0,685698	17,791556	3,203360	4,218004
13	AdaBoost	0,657573	0,627673	21,076134	3,666138	4,590875
14	Floresta Aleatória	0,902144	0,814442	10,503766	2,396875	3,240951
15	Floresta Aleatória 2	0,836228	0,788865	11,951596	2,620649	3,457108
16	Gradient Boosting	0,877989	0,834110	9,390446	2,374819	3,064384
17	Gradient Boosting 2	0,912872	0,815762	10,429037	2,417325	3,229402
18	XGBoosting	0,860510	0,824858	9,914164	2,441701	3,148677
19	XGBoosting 2	0,916763	0,809646	10,77528	2,402671	3,282572
20	RNA	0,784115	0,813508	18,047048	3,314156	4,248182

Tabela C. 7 – Resultados da predição da resistência  $f_{ck}$  do grupo B

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,695321	11,735283	2,654264	3,42568
2	Linear Múltipla	0,695186	0,677756	11,525505	2,669677	3,394923
3	Ridge	0,689260	0,674296	11,649289	2,671755	3,413105
4	Bayesiana	0,685727	0,671401	11,752823	2,678103	3,428239
5	Lasso	0,597688	0,590944	14,630493	2,992575	3,824983
6	Polinomial Grau 2	0,531483	-1,72e+19	6,15e+20	1,45e+09	2,48e+10
7	Polinomial Grau 3	0,942307	-8,37e+03	2,99e+05	1,49e+02	5,47e+02
8	Polinomial Grau 4	0,946842	-2,10e+02	7,57e+03	2,39e+01	8,70e+01
9	SVM	0,650740	0,634253	13,081463	2,781122	3,616831
10	KNN	0,853499	0,751409	8,891198	2,097029	2,981811
11	Árvore de Decisão	0,946844	0,807607	6,881181	1,705521	2,623201
12	Árvore de Decisão 2	0,843682	0,784067	7,723132	2,009542	2,779052
13	AdaBoost	0,701672	0,676816	11,559135	2,768846	3,399873
14	Floresta Aleatória	0,932135	0,865743	4,801875	1,469556	2,191318
15	Floresta Aleatória 2	0,871196	0,825806	6,230267	1,749872	2,496050
16	Gradient Boosting	0,892064	0,844495	5,561827	1,689404	2,358353
17	Gradient Boosting 2	0,939210	0,871581	4,593084	1,439658	2,143148
18	XGBoosting	0,880551	0,834166	5,931263	1,753118	2,435419
19	XGBoosting 2	0,939954	0,876555	4,415172	1,412645	2,101231
20	RNA	0,850512	0,816441	15,622338	2,871451	3,952510

Tabela C. 8 – Resultados da predição da resistência  $f_{ck}$  do grupo B sem outlier

	Algoritmos	Treino R <sup>2</sup>	Teste R <sup>2</sup>	MSE	MAE	RMSE
1	MQO	--	0,698352	11,697571	2,64932	3,420171
2	Linear Múltipla	0,722291	0,630471	12,608438	2,814273	3,550836
3	Ridge	0,715162	0,636288	12,409935	2,791044	3,522774
4	Bayesiana	0,715808	0,636235	12,411750	2,791640	3,523031
5	Lasso	0,616421	0,581543	14,277874	3,033766	3,778607
6	Polinomial Grau 2	0,872851	-8,17e+20	2,78e+22	9,84e+09	1,67e+11
7	Polinomial Grau 3	0,930506	-6,04e+01	2,09e+03	1,69e+01	4,57e+01
8	Polinomial Grau 4	0,934724	-7,77e+02	2,65e+04	3,00e+01	1,63e+02
9	SVM	0,671470	0,616419	13,087886	2,855648	3,617718
10	KNN	0,851345	0,767023	7,949217	1,949953	2,819436
11	Árvore de Decisão	0,934742	0,799458	6,842536	1,722903	2,615824
12	Árvore de Decisão 2	0,856899	0,769225	7,874072	1,998941	2,806078
13	AdaBoost	0,712436	0,693307	10,464417	2,636139	3,234875
14	Floresta Aleatória	0,922153	0,857419	4,864870	1,513227	2,205645
15	Floresta Aleatória 2	0,867418	0,814428	6,331765	1,829888	2,516300
16	Gradient Boosting	0,893958	0,835269	5,620663	1,746622	2,370794
17	Gradient Boosting 2	0,928857	0,854162	4,976016	1,493635	2,230699
18	XGBoosting	0,886339	0,827004	5,902668	1,799005	2,429541
19	XGBoosting 2	0,927240	0,869179	4,463638	1,437376	2,112732
20	RNA	0,855050	0,826706	11,464823	2,525488	3,385974

Tabela C. 9 – Resultados da predição da resistência  $f_{ck}$  do grupo C

	Algoritmos	Treino $R^2$	Teste $R^2$	MSE	MAE	RMSE
1	MQO	--	0,786354	7,221538	1,975968	2,687292
2	Linear Múltipla	0,784369	0,718926	8,478038	2,091700	2,911707
3	Ridge	0,758924	0,753776	7,426835	2,091104	2,725222
4	Bayesiana	0,762469	0,752079	7,478034	2,080785	2,734599
5	Lasso	0,645478	0,679011	9,681989	2,510869	3,111589
6	Polinomial Grau 2	0,967250	-3,05e+18	9,20e+19	1,49e+09	9,59e+09
7	Polinomial Grau 3	0,975331	0,753921	7,422463	1,243203	2,724420
8	Polinomial Grau 4	0,980122	-5,38e+17	1,62e+19	6,68e+08	4,03e+09
9	SVM	0,657785	0,632707	11,078627	2,413828	3,328457
10	KNN	0,935118	0,866481	4,027326	1,317999	2,006820
11	Árvore de Decisão	0,980159	0,887119	3,404808	0,899271	1,845212
12	Árvore de Decisão 2	0,941774	0,830450	5,114102	1,321002	2,261438
13	AdaBoost	0,942057	0,877056	3,708332	1,415522	1,925703
14	Floresta Aleatória	0,975664	0,927922	2,174066	0,909419	1,474471
15	Floresta Aleatória 2	0,960339	0,908689	2,754183	1,075525	1,659573
16	Gradient Boosting	0,977157	0,934903	1,963510	0,783530	1,401253
17	Gradient Boosting 2	0,979576	0,924045	2,291010	0,820913	1,513608
18	XGBoosting	0,976013	0,933859	1,994991	0,789816	1,412441
19	XGBoosting 2	0,978776	0,925365	2,251207	0,802726	1,500402
20	RNA	0,954137	0,926272	5,888705	1,768842	2,426665

Tabela C. 10 – Resultados da predição da resistência  $f_{ck}$  do grupo C sem outlier

	Algoritmos	Treino $R^2$	Teste $R^2$	MSE	MAE	RMSE
1	MQO	--	0,788939	7,089193	1,950099	2,662554
2	Linear Múltipla	0,798851	0,727906	8,010801	2,139322	2,830336
3	Ridge	0,777058	0,732296	7,881554	2,160369	2,807411
4	Bayesiana	0,779963	0,733203	7,854875	2,149089	2,802655
5	Lasso	0,676396	0,653915	10,189199	2,546396	3,192053
6	Polinomial Grau 2	0,963267	-9,54e+21	2,81e+23	1,05e+11	5,30e+11
7	Polinomial Grau 3	0,972193	-1,55e+21	4,56e+22	4,33e+10	2,13e+11
8	Polinomial Grau 4	0,976450	-5,74e+18	1,69e+20	2,88e+09	1,30e+10
		1				
9	SVM	0,705223	0,727151	8,033028	2,059094	2,834259
10	KNN	0,940289	0,859380	4,140031	1,242555	2,034706
11	Árvore de Decisão	0,977053	0,913277	2,553230	0,901591	1,597883
12	Árvore de Decisão 2	0,933146	0,903543	2,839813	1,117990	1,685174
13	AdaBoost	0,931378	0,864791	3,980708	1,365076	1,995171
14	Floresta Aleatória	0,972695	0,930267	2,053024	0,876612	1,432837
15	Floresta Aleatória 2	0,957028	0,911346	2,610085	1,047534	1,615575
16	Gradient Boosting	0,973551	0,934810	1,919259	0,771537	1,385373
17	Gradient Boosting 2	0,976078	0,934494	1,928570	0,791477	1,388729
18	XGBoosting	0,971953	0,933342	1,962483	0,7991259	1,400886
19	XGBoosting 2	0,975421	0,920212	2,349060	0,843948	1,532664
20	RNA	0,927395	0,910216	6,804340	1,995777	2,608513

## Apêndice D – Dados dos *Data Sets* 1 e 2 Usados na Predição das Resistências Mecânicas dos Concretos

Tabela D. 1 – Dados do *Data Set* 1

Amostra	Tipos de Concreto	Idade	Relação a/c	Cimento	Areia	Brita	Água	Slump	Fck	Fct
1	0,00	7	0,5	440	689	1098	225	7,5	17,51	2,13
2	0,00	7	0,5	440	689	1098	225	7,5	20,09	2,28
3	0,00	7	0,5	440	689	1098	225	7,5	18,77	2,22
4	0,00	7	0,5	440	689	1098	225	7,5	18,18	2,06
5	0,00	14	0,5	440	689	1098	225	7,5	22,45	2,30
6	0,00	14	0,5	440	689	1098	225	7,5	22,70	2,56
7	0,00	14	0,5	440	689	1098	225	7,5	18,37	2,49
8	0,00	14	0,5	440	689	1098	225	7,5	18,80	1,98
9	0,00	28	0,5	440	689	1098	225	7,5	28,51	3,18
10	0,00	28	0,5	440	689	1098	225	7,5	23,09	2,75
11	0,00	28	0,5	440	689	1098	225	7,5	25,60	2,84
12	0,00	28	0,5	440	689	1098	225	7,5	23,51	2,62
13	0,00	56	0,5	440	689	1098	225	7,5	26,10	2,91
14	0,00	56	0,5	440	689	1098	225	7,5	23,44	2,70
15	0,00	56	0,5	440	689	1098	225	7,5	26,33	3,03
16	0,00	56	0,5	440	689	1098	225	7,5	24,79	3,33
17	0,50	7	0,5	440	689	1098	225	8,7	19,78	2,36
18	0,50	7	0,5	440	689	1098	225	8,7	20,00	2,17
19	0,50	7	0,5	440	689	1098	225	8,7	19,20	1,94
20	0,50	7	0,5	440	689	1098	225	8,7	20,84	2,28
21	0,50	14	0,5	440	689	1098	225	8,7	18,75	2,47
22	0,50	14	0,5	440	689	1098	225	8,7	20,58	2,36
23	0,50	14	0,5	440	689	1098	225	8,7	22,80	2,09
24	0,50	14	0,5	440	689	1098	225	8,7	23,37	2,49
25	0,50	28	0,5	440	689	1098	225	8,7	25,95	2,90
26	0,50	28	0,5	440	689	1098	225	8,7	24,61	3,30
27	0,50	28	0,5	440	689	1098	225	8,7	27,77	2,64
28	0,50	28	0,5	440	689	1098	225	8,7	24,87	3,16
29	0,50	56	0,5	440	689	1098	225	8,7	23,69	2,96
30	0,50	56	0,5	440	689	1098	225	8,7	24,82	3,40
31	0,50	56	0,5	440	689	1098	225	8,7	25,91	3,25
32	0,50	56	0,5	440	689	1098	225	8,7	26,45	2,65
33	1,00	7	0,5	440	689	1098	225	8,6	21,71	1,99
34	1,00	7	0,5	440	689	1098	225	8,6	20,84	2,76
35	1,00	7	0,5	440	689	1098	225	8,6	19,40	2,42
36	1,00	7	0,5	440	689	1098	225	8,6	18,74	1,94
37	1,00	14	0,5	440	689	1098	225	8,6	22,09	1,83
38	1,00	14	0,5	440	689	1098	225	8,6	20,61	2,20

39	1,00	14	0,5	440	689	1098	225	8,6	24,40	2,79
40	1,00	14	0,5	440	689	1098	225	8,6	22,49	2,73
41	1,00	28	0,5	440	689	1098	225	8,6	24,75	3,17
42	1,00	28	0,5	440	689	1098	225	8,6	26,45	2,72
43	1,00	28	0,5	440	689	1098	225	8,6	23,36	3,13
44	1,00	28	0,5	440	689	1098	225	8,6	27,00	3,08
45	1,00	56	0,5	440	689	1098	225	8,6	24,95	3,39
46	1,00	56	0,5	440	689	1098	225	8,6	26,02	3,06
47	1,00	56	0,5	440	689	1098	225	8,6	26,80	2,62
48	1,00	56	0,5	440	689	1098	225	8,6	24,64	3,04
49	0,00	7	0,7	370	810	1070	245	7,2	12,38	1,32
50	0,00	7	0,7	370	810	1070	245	7,2	10,91	1,27
51	0,00	7	0,7	370	810	1070	245	7,2	10,50	1,40
52	0,00	7	0,7	370	810	1070	245	7,2	10,51	1,35
53	0,00	14	0,7	370	810	1070	245	7,2	13,14	1,55
54	0,00	14	0,7	370	810	1070	245	7,2	13,70	1,35
55	0,00	14	0,7	370	810	1070	245	7,2	13,51	1,48
56	0,00	14	0,7	370	810	1070	245	7,2	13,34	1,52
57	0,00	28	0,7	370	810	1070	245	7,2	14,75	1,64
58	0,00	28	0,7	370	810	1070	245	7,2	14,45	1,67
59	0,00	28	0,7	370	810	1070	245	7,2	14,07	1,62
60	0,00	28	0,7	370	810	1070	245	7,2	13,15	1,68
61	0,00	56	0,7	370	810	1070	245	7,2	14,77	1,79
62	0,00	56	0,7	370	810	1070	245	7,2	14,66	1,64
63	0,00	56	0,7	370	810	1070	245	7,2	14,18	1,68
64	0,00	56	0,7	370	810	1070	245	7,2	14,54	1,77
65	0,50	7	0,7	370	810	1070	245	7,8	12,27	1,29
66	0,50	7	0,7	370	810	1070	245	7,8	12,54	1,34
67	0,50	7	0,7	370	810	1070	245	7,8	11,87	1,27
68	0,50	7	0,7	370	810	1070	245	7,8	12,65	1,41
69	0,50	14	0,7	370	810	1070	245	7,8	14,71	1,58
70	0,50	14	0,7	370	810	1070	245	7,8	14,53	1,53
71	0,50	14	0,7	370	810	1070	245	7,8	15,31	1,51
72	0,50	14	0,7	370	810	1070	245	7,8	13,47	1,57
73	0,50	28	0,7	370	810	1070	245	7,8	16,56	2,10
74	0,50	28	0,7	370	810	1070	245	7,8	15,26	1,85
75	0,50	28	0,7	370	810	1070	245	7,8	16,77	1,92
76	0,50	28	0,7	370	810	1070	245	7,8	15,50	1,90
77	0,50	56	0,7	370	810	1070	245	7,8	15,96	2,16
78	0,50	56	0,7	370	810	1070	245	7,8	16,73	2,13
79	0,50	56	0,7	370	810	1070	245	7,8	15,65	2,01
80	0,50	56	0,7	370	810	1070	245	7,8	16,38	1,90
81	1,00	7	0,7	370	810	1070	245	6,9	14,10	1,36
82	1,00	7	0,7	370	810	1070	245	6,9	13,97	1,35
83	1,00	7	0,7	370	810	1070	245	6,9	14,26	1,42

84	1,00	7	0,7	370	810	1070	245	6,9	14,71	1,40
85	1,00	14	0,7	370	810	1070	245	6,9	15,17	1,57
86	1,00	14	0,7	370	810	1070	245	6,9	15,24	1,40
87	1,00	14	0,7	370	810	1070	245	6,9	14,02	1,47
88	1,00	14	0,7	370	810	1070	245	6,9	16,40	1,55
89	1,00	28	0,7	370	810	1070	245	6,9	16,61	1,74
90	1,00	28	0,7	370	810	1070	245	6,9	16,56	2,32
91	1,00	28	0,7	370	810	1070	245	6,9	15,06	1,99
92	1,00	28	0,7	370	810	1070	245	6,9	16,21	1,78
93	1,00	56	0,7	370	810	1070	245	6,9	15,41	1,95
94	1,00	56	0,7	370	810	1070	245	6,9	16,83	2,24
95	1,00	56	0,7	370	810	1070	245	6,9	17,47	1,97
96	1,00	56	0,7	370	810	1070	245	6,9	17,39	2,15
97	0,25	7	0,5	440	689	1098	225	7,8	19,67	2,16
98	0,25	7	0,5	440	689	1098	225	7,8	21,19	2,24
99	0,25	7	0,5	440	689	1098	225	7,8	18,29	2,12
100	0,25	7	0,5	440	689	1098	225	7,8	20,00	2,27
101	0,25	14	0,5	440	689	1098	225	7,8	23,77	2,34
102	0,25	14	0,5	440	689	1098	225	7,8	20,49	2,73
103	0,25	14	0,5	440	689	1098	225	7,8	19,00	2,09
104	0,25	14	0,5	440	689	1098	225	7,8	23,55	2,34
105	0,25	28	0,5	440	689	1098	225	7,8	24,93	3,26
106	0,25	28	0,5	440	689	1098	225	7,8	27,22	2,95
107	0,25	28	0,5	440	689	1098	225	7,8	26,86	2,80
108	0,25	28	0,5	440	689	1098	225	7,8	23,47	3,04
109	0,25	56	0,5	440	689	1098	225	7,8	25,95	3,26
110	0,25	56	0,5	440	689	1098	225	7,8	26,68	2,95
111	0,25	56	0,5	440	689	1098	225	7,8	26,86	3,36
112	0,25	56	0,5	440	689	1098	225	7,8	24,84	3,04
113	0,75	7	0,5	440	689	1098	225	9,1	21,33	2,23
114	0,75	7	0,5	440	689	1098	225	9,1	19,62	2,17
115	0,75	7	0,5	440	689	1098	225	9,1	21,95	2,46
116	0,75	7	0,5	440	689	1098	225	9,1	20,08	2,17
117	0,75	14	0,5	440	689	1098	225	9,1	23,14	2,28
118	0,75	14	0,5	440	689	1098	225	9,1	20,95	2,36
119	0,75	14	0,5	440	689	1098	225	9,1	24,57	2,48
120	0,75	14	0,5	440	689	1098	225	9,1	21,08	2,53
121	0,75	28	0,5	440	689	1098	225	9,1	27,13	2,92
122	0,75	28	0,5	440	689	1098	225	9,1	25,71	3,20
123	0,75	28	0,5	440	689	1098	225	9,1	24,09	3,03
124	0,75	28	0,5	440	689	1098	225	9,1	27,15	3,11
125	0,75	56	0,5	440	689	1098	225	9,1	25,97	3,42
126	0,75	56	0,5	440	689	1098	225	9,1	28,23	3,27
127	0,75	56	0,5	440	689	1098	225	9,1	25,12	2,81
128	0,75	56	0,5	440	689	1098	225	9,1	24,71	3,07

Tabela D. 2 – Dados do *Data Set 2*

Amostras	Agregado	Cimento	Idade	Areia	Brita	Relação a/c	Aditivo	Fc	Grupos
1	Gnaisse	CP III 32	3	1,58	2,33	0,45	0,58	23,3	B
2	Gnaisse	CP III 32	7	1,58	2,33	0,45	0,58	38,2	B
3	Gnaisse	CP III 32	14	1,58	2,33	0,45	0,58	39	C
4	Gnaisse	CP III 32	28	1,58	2,33	0,45	0,58	42,8	C
5	Gnaisse	CP III 32	56	1,58	2,33	0,45	0,58	52,4	A
6	Gnaisse	CP III RS 40	3	1,83	2,33	0,45	0,35	22,4	B
7	Gnaisse	CP III RS 40	3	1,83	2,33	0,45	0,35	24,64	B
8	Gnaisse	CP III RS 40	3	1,83	2,33	0,45	0,35	20,16	B
9	Gnaisse	CP III RS 40	3	2,50	2,09	0,45	3	28,6	B
10	Gnaisse	CP III RS 40	3	1,81	2,69	0,45	3	31,46	B
11	Gnaisse	CP III RS 40	3	1,73	2,62	0,45	3	25,74	B
12	Gnaisse	CP III RS 40	7	1,83	2,33	0,45	0,35	39,2	B
13	Gnaisse	CP III RS 40	7	1,83	2,33	0,45	0,35	43,12	B
14	Gnaisse	CP III RS 40	7	1,83	2,33	0,45	0,35	35,28	B
15	Gnaisse	CP III RS 40	7	2,50	2,09	0,45	3	42,3	B
16	Gnaisse	CP III RS 40	7	1,81	2,69	0,45	3	46,53	C
17	Gnaisse	CP III RS 40	7	1,73	2,62	0,45	3	38,07	B
18	Gnaisse	CP III RS 40	14	1,83	2,33	0,45	0,35	43,7	C
19	Gnaisse	CP III RS 40	14	1,83	2,33	0,45	0,35	48,07	C
20	Gnaisse	CP III RS 40	14	1,83	2,33	0,45	0,35	39,33	C
21	Gnaisse	CP III RS 40	14	2,50	2,09	0,45	3	47,9	C
22	Gnaisse	CP III RS 40	14	1,81	2,69	0,45	3	52,69	C
23	Gnaisse	CP III RS 40	14	1,73	2,62	0,45	3	43,11	C
24	Gnaisse	CP III RS 40	28	1,83	2,33	0,45	0,35	44,7	C
25	Gnaisse	CP III RS 40	28	1,83	2,33	0,45	0,35	49,17	C
26	Gnaisse	CP III RS 40	28	1,83	2,33	0,45	0,35	40,23	C
27	Gnaisse	CP III RS 40	28	2,50	2,09	0,45	3	52,6	C
28	Gnaisse	CP III RS 40	28	1,81	2,69	0,45	3	57,86	C
29	Gnaisse	CP III RS 40	28	1,73	2,62	0,45	3	47,34	C
30	Gnaisse	CP V ARI	3	1,58	2,33	0,45	0,5	33,5	B
31	Gnaisse	CP V ARI	7	1,58	2,33	0,45	0,5	38,8	B
32	Gnaisse	CP V ARI	14	1,58	2,33	0,45	0,5	44,2	A
33	Gnaisse	CP V ARI	28	1,58	2,33	0,45	0,5	46,2	A
34	Gnaisse	CP V ARI	56	1,58	2,33	0,45	0,5	49,2	A
35	Gnaisse	CP I S 32	28	1,81	3,69	0,45	0	35	A
36	Sienito	CP III RS 40	3	1,63	2,32	0,45	3	31,2	A
37	Sienito	CP III RS 40	3	1,63	2,32	0,45	3	34,32	A
38	Sienito	CP III RS 40	3	1,63	2,32	0,45	3	28,08	A
39	Sienito	CP III RS 40	7	1,63	2,32	0,45	3	39,4	A
40	Sienito	CP III RS 40	7	1,63	2,32	0,45	3	43,34	A
41	Sienito	CP III RS 40	7	1,63	2,32	0,45	3	35,46	A
42	Sienito	CP III RS 40	14	1,63	2,32	0,45	3	51,4	A
43	Sienito	CP III RS 40	14	1,63	2,32	0,45	3	56,54	A
44	Sienito	CP III RS 40	14	1,63	2,32	0,45	3	46,26	A

45	Sienito	CP III RS 40	28	1,63	2,32	0,45	3	57,4	A
46	Sienito	CP III RS 40	28	1,63	2,32	0,45	3	63,14	A
47	Sienito	CP III RS 40	28	1,63	2,32	0,45	3	51,66	A
48	Traquito	CP III 32	3	1,58	2,33	0,45	0,67	12,5	A
49	Traquito	CP III 32	7	1,58	2,33	0,45	0,67	26,1	A
50	Traquito	CP III 32	14	1,58	2,33	0,45	0,67	29,6	A
51	Traquito	CP III 32	28	1,58	2,33	0,45	0,67	36	A
52	Traquito	CP III 32	56	1,58	2,33	0,45	0,67	37,7	A
53	Basalto	CP II F 40	3	2,24	2,06	0,46	0,64	34,9	A
54	Basalto	CP II F 40	7	2,24	2,06	0,46	0,64	46,4	A
55	Basalto	CP II F 40	7	2,24	2,06	0,46	0,64	46,4	A
56	Basalto	CP II F 40	28	2,24	2,06	0,46	0,64	65,4	A
57	Gnaisse	CP III 32	28	2,15	2,38	0,46	0	45	A
58	Gnaisse	CP III 32	28	2,15	2,38	0,46	0	45	A
59	Basalto	CP II E 32	28	1,62	2,54	0,47	0	29	A
60	Basalto	CP II E 32	28	1,62	2,54	0,47	0	30	A
61	Basalto	CP II E 32	28	1,62	2,54	0,47	0	31	A
62	Basalto	CP II E 32	28	1,62	2,54	0,47	0	29	A
63	Basalto	CP II E 32	28	1,62	2,54	0,47	0	30	A
64	Basalto	CP II E 32	28	1,62	2,54	0,47	0	31	A
65	Basalto	CP II F 40	3	1,02	2,34	0,47	1,53	29,3	A
66	Basalto	CP II F 40	7	1,02	2,34	0,47	1,53	40	A
67	Basalto	CP II F 40	28	1,02	2,34	0,47	1,53	55,6	A
68	Basalto	CP II F 40	28	1,02	2,34	0,47	1,53	55,6	A
69	Granito	CP III RS 40	7	1,43	1,93	0,47	0,31	24,27	A
70	Granito	CP III RS 40	7	1,43	1,93	0,47	0,31	23,62	A
71	Granito	CP III RS 40	7	1,43	1,93	0,47	0,31	26,73	A
72	Granito	CP III RS 40	7	1,43	1,93	0,47	0,31	24,29	A
73	Granito	CP III RS 40	7	1,43	1,93	0,47	0,31	23,04	A
74	Granito	CP III RS 40	7	1,43	1,93	0,47	0,31	22,22	A
75	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	18,72	A
76	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	22,67	A
77	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	25,96	A
78	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	24,35	A
79	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	22,59	A
80	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	24,89	A
81	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	24,1	A
82	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	24,37	A
83	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	25,87	A
84	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	26,83	A
85	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	28,68	A
86	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	22,23	A
87	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	24,6	A
88	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	28,48	A
89	Granito	CP III RS 40	7	1,43	3,33	0,47	0,31	23,28	A
90	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	28,76	A
91	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	30,66	A

92	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	27,84	A
93	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	27,44	A
94	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	28,33	A
95	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	28,99	A
96	Granito	CP III RS 40	7	2,10	3,35	0,47	0,31	26,89	A
97	Granito	CP III RS 40	28	1,43	1,93	0,47	0,31	31,6	A
98	Granito	CP III RS 40	28	1,43	1,93	0,47	0,31	35,75	A
99	Granito	CP III RS 40	28	1,43	1,93	0,47	0,31	31,63	A
100	Granito	CP III RS 40	28	1,43	1,93	0,47	0,31	31,8	A
101	Granito	CP III RS 40	28	1,43	1,93	0,47	0,31	33,57	A
102	Granito	CP III RS 40	28	1,43	1,93	0,47	0,31	32,1	A
103	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	32,12	A
104	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	33,1	A
105	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	34,96	A
106	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	34,08	A
107	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	34,29	A
108	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	31,31	A
109	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	31,09	A
110	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	28,97	A
111	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	33,44	A
112	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	33,97	A
113	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	36,9	A
114	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	28,04	A
115	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	37,6	A
116	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	39,05	A
117	Granito	CP III RS 40	28	1,43	3,33	0,47	0,31	38,15	A
118	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	31,67	A
119	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	36,65	A
120	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	34,83	A
121	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	32,89	A
122	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	28,59	A
123	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	35,53	A
124	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	37,72	A
125	Granito	CP III RS 40	28	2,10	3,35	0,47	0,31	34,96	A
126	Granito	CP III RS 40	56	1,43	1,93	0,47	0,31	33,1	A
127	Granito	CP III RS 40	56	1,43	1,93	0,47	0,31	31,9	A
128	Granito	CP III RS 40	56	1,43	1,93	0,47	0,31	33,7	A
129	Granito	CP III RS 40	56	1,43	1,93	0,47	0,31	34,59	A
130	Granito	CP III RS 40	56	1,43	1,93	0,47	0,31	35,74	A
131	Granito	CP III RS 40	56	1,43	1,93	0,47	0,31	35,13	A
132	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	38,66	A
133	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	29,67	A
134	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	35,27	A
135	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	31,66	A
136	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	33,73	A
137	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	36,7	A
138	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	31,77	A

139	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	37,17	A
140	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	37,91	A
141	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	38,78	A
142	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	37,08	A
143	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	39,01	A
144	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	29,6	A
145	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	42,06	A
146	Granito	CP III RS 40	56	1,43	3,33	0,47	0,31	34,24	A
147	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	38,64	A
148	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	35,42	A
149	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	31,84	A
150	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	39,18	A
151	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	34,69	A
152	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	41,57	A
153	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	44	A
154	Granito	CP III RS 40	56	2,10	3,35	0,47	0,31	43,56	A
155	Granulito	CP II F 32	3	2,10	3,35	0,47	0	23,4	A
156	Granulito	CP II F 32	3	2,10	3,35	0,47	0	22,2	A
157	Granulito	CP II F 32	3	2,10	3,35	0,47	0	21,2	A
158	Granulito	CP II F 32	7	2,10	3,35	0,47	0	22,34	A
159	Granulito	CP II F 32	7	2,10	3,35	0,47	0	25,35	A
160	Granulito	CP II F 32	7	2,10	3,35	0,47	0	24,25	A
161	Granulito	CP II F 32	28	2,10	3,35	0,47	0	32,45	A
162	Granulito	CP II F 32	28	2,10	3,35	0,47	0	31,5	A
163	Granulito	CP II F 32	28	2,10	3,35	0,47	0	32,3	A
164	Micaxisto	CP II F 32	3	2,10	3,35	0,47	0	16,7	A
165	Micaxisto	CP II F 32	3	2,10	3,35	0,47	0	19,4	A
166	Micaxisto	CP II F 32	3	2,10	3,35	0,47	0	21	A
167	Micaxisto	CP II F 32	7	2,10	3,35	0,47	0	22,19	A
168	Micaxisto	CP II F 32	7	2,10	3,35	0,47	0	23,04	A
169	Micaxisto	CP II F 32	7	2,10	3,35	0,47	0	24,43	A
170	Micaxisto	CP II F 32	28	2,10	3,35	0,47	0	27,4	A
171	Micaxisto	CP II F 32	28	2,10	3,35	0,47	0	30,1	A
172	Micaxisto	CP II F 32	28	2,10	3,35	0,47	0	29,2	A
173	Basalto	CP II E 32	28	1,88	2,54	0,49	0	34,6	A
174	Basalto	CP II E 32	28	1,88	2,54	0,49	0	44,2	A
175	Basalto	CP II E 32	28	1,88	2,54	0,49	0	44,2	A
176	Basalto	CP II E 32	28	1,88	2,54	0,49	0	39,8	A
177	Basalto	CP II E 32	28	1,88	2,54	0,49	0	37,7	A
178	Basalto	CP II E 32	28	1,88	2,54	0,49	0	35,9	A
179	Basalto	CP II E 32	28	1,88	2,54	0,49	0	39,8	A
180	Basalto	CP II F 40	3	2,34	2,16	0,49	1,31	26,5	A
181	Basalto	CP II F 40	7	2,34	2,16	0,49	1,31	33	A
182	Basalto	CP II F 40	28	2,34	2,16	0,49	1,31	46,5	A
183	Basalto	CP II Z 32	7	1,88	2,54	0,49	0	28,2	A
184	Basalto	CP II Z 32	7	1,88	2,54	0,49	0	29,2	A
185	Basalto	CP II Z 32	7	1,88	2,54	0,49	0	30,2	A

186	Basalto	CP II Z 32	28	1,88	2,54	0,49	0	35,3	A
187	Basalto	CP II Z 32	28	1,88	2,54	0,49	0	36,3	A
188	Basalto	CP II Z 32	28	1,88	2,54	0,49	0	37,3	A
189	Calcario	CP II E 32	28	1,88	2,54	0,49	0	29	A
190	Calcario	CP II E 32	28	1,88	2,54	0,49	0	25,5	A
191	Calcario	CP II E 32	28	1,88	2,54	0,49	0	32,5	A
192	Calcario	CP II E 32	28	1,88	2,54	0,49	0	24,7	A
193	Calcario	CP II E 32	28	1,88	2,54	0,49	0	35,1	A
194	Gnaisse	CP III 32	28	1,88	2,54	0,49	0	40	A
195	Granito	CP II E 32	28	1,88	2,54	0,49	0	29,9	A
196	Granito	CP II E 32	28	1,88	2,54	0,49	0	29,4	A
197	Granito	CP II E 32	28	1,88	2,54	0,49	0	29,1	A
198	Granito	CP II E 32	28	1,88	2,54	0,49	0	28,7	A
199	Granito	CP II E 32	28	1,88	2,54	0,49	0	29,9	A
200	Granito	CP II F 32	28	2,24	2,54	0,49	0,6	35,97	A
201	Granito	CP II F 32	28	1,76	2,87	0,49	0,6	32,6	A
202	Granito	CP II F 32	28	1,76	2,87	0,49	0,6	31,27	A
203	Granito	CP II F 32	28	1,76	2,87	0,49	0,6	33,55	A
204	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	36,17	A
205	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	34,39	A
206	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	38,16	A
207	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	34,39	A
208	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	35,89	A
209	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	37,42	A
210	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	35,49	A
211	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	46,39	A
212	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	40,71	A
213	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	37,36	A
214	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	30,17	A
215	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	30,17	A
216	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	36,17	A
217	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	34,89	A
218	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	32,86	A
219	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	33,26	A
220	Granito	CP II F 32	28	2,00	3,00	0,49	0,6	34,43	A
221	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	36,93	A
222	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	37,84	A
223	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	38,69	A
224	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	35,28	A
225	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	34,01	A
226	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	36,73	A
227	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	37,43	A
228	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	36,19	A
229	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	39,31	A
230	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	41,37	A
231	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	38,71	A
232	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	28,78	A

233	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	28,78	A
234	Granito	CP II F 32	28	1,88	2,54	0,49	0,6	36,93	A
235	Basalto	CP II F 32	7	1,41	3,30	0,50	0,6	29,68	A
236	Basalto	CP II F 32	7	1,41	3,30	0,50	0,6	31,73	A
237	Basalto	CP II F 32	7	1,41	3,30	0,50	0,6	30,81	A
238	Basalto	CP II F 32	28	1,41	3,30	0,50	0,6	38,79	A
239	Basalto	CP II F 32	28	1,41	3,30	0,50	0,6	41,1	A
240	Basalto	CP II F 32	28	1,41	3,30	0,50	0,6	40,98	A
241	Basalto	CP II F 40	3	2,12	2,73	0,50	0,66	27,8	A
242	Basalto	CP II F 40	7	2,12	2,73	0,50	0,66	39,1	A
243	Basalto	CP II F 40	28	2,12	2,73	0,50	0,66	55,1	A
244	Basalto	CP II Z 32	7	1,60	2,50	0,50	0	29,6	A
245	Basalto	CP II Z 32	7	1,60	2,50	0,50	0	30,6	A
246	Basalto	CP II Z 32	7	1,60	2,50	0,50	0	31,6	A
247	Basalto	CP II Z 32	28	1,60	2,50	0,50	0	35,5	A
248	Basalto	CP II Z 32	28	1,60	2,50	0,50	0	36,5	A
249	Basalto	CP II Z 32	28	1,60	2,50	0,50	0	37,5	A
250	Calcario	CP III RS 40	3	1,36	2,85	0,50	0,6	6,49	A
251	Calcario	CP III RS 40	3	1,36	2,85	0,50	0,6	6,45	A
252	Calcario	CP III RS 40	3	1,36	2,85	0,50	0,6	6,25	A
253	Calcario	CP III RS 40	3	1,87	2,57	0,50	0,6	6,51	A
254	Calcario	CP III RS 40	3	1,87	2,57	0,50	0,6	6,46	A
255	Calcario	CP III RS 40	3	2,36	2,76	0,50	0,6	6,26	A
256	Calcario	CP III RS 40	7	1,36	2,85	0,50	0,6	18,21	A
257	Calcario	CP III RS 40	7	1,36	2,85	0,50	0,6	18,08	A
258	Calcario	CP III RS 40	7	1,36	2,85	0,50	0,6	17,51	A
259	Calcario	CP III RS 40	7	1,87	2,57	0,50	0,6	18,24	A
260	Calcario	CP III RS 40	7	1,87	2,57	0,50	0,6	18,11	A
261	Calcario	CP III RS 40	7	2,36	2,76	0,50	0,6	17,54	A
262	Calcario	CP III RS 40	28	1,36	2,85	0,50	0,6	32,64	A
263	Calcario	CP III RS 40	28	1,36	2,85	0,50	0,6	32,4	A
264	Calcario	CP III RS 40	28	1,36	2,85	0,50	0,6	31,39	A
265	Calcario	CP III RS 40	28	1,36	2,85	0,50	0,6	32,1	A
266	Calcario	CP III RS 40	28	1,87	2,57	0,50	0,6	31,63	A
267	Calcario	CP III RS 40	28	1,87	2,57	0,50	0,6	32,7	A
268	Calcario	CP III RS 40	28	1,87	2,57	0,50	0,6	32,45	A
269	Calcario	CP III RS 40	28	2,36	2,76	0,50	0,6	31,44	A
270	Calcario	CP III RS 40	28	2,36	2,76	0,50	0,6	32,15	A
271	Calcario	CP III RS 40	28	2,36	2,76	0,50	0,6	31,68	A
272	Gnaïsse	CP III 32	3	1,41	3,30	0,50	0,61	24,2	A
273	Gnaïsse	CP III 32	7	1,41	3,30	0,50	0,61	31,5	A
274	Gnaïsse	CP III 32	14	1,41	3,30	0,50	0,61	38,2	A
275	Gnaïsse	CP III 32	28	1,41	3,30	0,50	0,61	43,4	A
276	Gnaïsse	CP III 32	56	1,41	3,30	0,50	0,61	52	A
277	Gnaïsse	CP III 32	28	1,60	2,50	0,50	0	30	A
278	Gnaïsse	CP III 32	28	1,60	2,50	0,50	0	35	A
279	Gnaïsse	CP III RS 40	3	1,60	2,50	0,50	0,35	20,6	A

280	Gnaïsse	CP III RS 40	3	1,60	2,50	0,50	0,35	22,66	A
281	Gnaïsse	CP III RS 40	3	1,60	2,50	0,50	0,35	18,54	A
282	Gnaïsse	CP III RS 40	3	1,60	2,50	0,50	3	27,4	A
283	Gnaïsse	CP III RS 40	3	1,60	2,50	0,50	3	30,14	A
284	Gnaïsse	CP III RS 40	3	1,60	2,50	0,50	3	24,66	A
285	Gnaïsse	CP III RS 40	7	2,50	2,30	0,50	0	18	A
286	Gnaïsse	CP III RS 40	7	2,44	2,25	0,50	0	25	A
287	Gnaïsse	CP III RS 40	7	2,42	2,59	0,50	0	31	A
288	Gnaïsse	CP III RS 40	7	1,60	2,50	0,50	0,35	34,8	A
289	Gnaïsse	CP III RS 40	7	1,60	2,50	0,50	0,35	38,28	A
290	Gnaïsse	CP III RS 40	7	1,60	2,50	0,50	0,35	31,32	A
291	Gnaïsse	CP III RS 40	7	1,60	2,50	0,50	3	35,3	A
292	Gnaïsse	CP III RS 40	7	1,60	2,50	0,50	3	38,83	A
293	Gnaïsse	CP III RS 40	7	1,60	2,50	0,50	3	31,77	A
294	Gnaïsse	CP III RS 40	14	1,60	2,50	0,50	0,35	37,4	A
295	Gnaïsse	CP III RS 40	14	1,60	2,50	0,50	0,35	41,14	A
296	Gnaïsse	CP III RS 40	14	1,60	2,50	0,50	0,35	33,66	A
297	Gnaïsse	CP III RS 40	14	1,60	2,50	0,50	3	41,1	A
298	Gnaïsse	CP III RS 40	14	1,60	2,50	0,50	3	45,21	A
299	Gnaïsse	CP III RS 40	14	1,60	2,50	0,50	3	36,99	A
300	Gnaïsse	CP III RS 40	28	2,50	2,30	0,50	0	26	A
301	Gnaïsse	CP III RS 40	28	2,44	2,25	0,50	0	32	A
302	Gnaïsse	CP III RS 40	28	2,42	2,59	0,50	0	44	A
303	Gnaïsse	CP III RS 40	28	1,60	2,50	0,50	0,35	38,8	A
304	Gnaïsse	CP III RS 40	28	1,60	2,50	0,50	0,35	42,68	A
305	Gnaïsse	CP III RS 40	28	1,60	2,50	0,50	0,35	34,92	A
306	Gnaïsse	CP III RS 40	28	1,60	2,50	0,50	3	48,8	A
307	Gnaïsse	CP III RS 40	28	1,60	2,50	0,50	3	53,68	A
308	Gnaïsse	CP III RS 40	28	1,60	2,50	0,50	3	43,92	A
309	Gnaïsse	CP IV 32	7	1,82	2,73	0,50	0	14	A
310	Gnaïsse	CP IV 32	7	1,82	2,73	0,50	0	17	A
311	Gnaïsse	CP IV 32	7	1,82	2,73	0,50	0	25	A
312	Gnaïsse	CP IV 32	28	1,82	2,73	0,50	0	22	A
313	Gnaïsse	CP IV 32	28	1,82	2,73	0,50	0	25	A
314	Gnaïsse	CP IV 32	28	1,82	2,73	0,50	0	37	A
315	Gnaïsse	CP V ARI	3	1,36	2,85	0,50	0,44	34,4	A
316	Gnaïsse	CP V ARI	7	1,36	2,85	0,50	0,44	36	A
317	Gnaïsse	CP V ARI	14	1,36	2,85	0,50	0,44	36,8	A
318	Gnaïsse	CP V ARI	28	1,36	2,85	0,50	0,44	37	A
319	Gnaïsse	CP V ARI	56	1,36	2,85	0,50	0,44	40,7	A
320	Gnaïsse	CP V ARI	7	2,11	2,98	0,50	0	27	A
321	Gnaïsse	CP V ARI	7	2,03	3,91	0,50	0	38	A
322	Gnaïsse	CP V ARI	7	2,11	2,98	0,50	0	44	A
323	Gnaïsse	CP V ARI	28	2,11	2,98	0,50	0	32	A
324	Gnaïsse	CP V ARI	28	2,03	3,91	0,50	0	41	A
325	Gnaïsse	CP V ARI	28	2,11	2,98	0,50	0	47	A
326	Gnaïsse	CP I S 32	28	1,60	2,50	0,5	0	30	A

327	Gnaisse	CP II E 32	28	1,60	2,50	0,50	0	30	A
328	Gnaisse	CP II F 32	7	1,40	2,10	0,50	0	24	A
329	Gnaisse	CP II F 32	7	2,90	2,50	0,50	0	33	A
330	Gnaisse	CP II F 32	7	2,40	2,20	0,50	0	38	A
331	Gnaisse	CP II F 32	28	1,40	2,10	0,50	0	28	A
332	Gnaisse	CP II F 32	28	2,90	2,50	0,50	0	37	A
333	Gnaisse	CP II F 32	28	2,40	2,20	0,50	0	46	A
334	Gnaisse	CP II Z 32	7	1,40	2,10	0,50	0	17,51	A
335	Gnaisse	CP II Z 32	7	1,40	2,10	0,50	0	20,09	A
336	Gnaisse	CP II Z 32	7	1,40	2,10	0,50	0	18,77	A
337	Gnaisse	CP II Z 32	7	1,40	2,10	0,50	0	18,18	A
338	Gnaisse	CP II Z 32	14	1,40	2,10	0,50	0	22,45	A
339	Gnaisse	CP II Z 32	14	1,40	2,10	0,50	0	22,70	A
340	Gnaisse	CP II Z 32	14	1,40	2,10	0,50	0	18,37	A
341	Gnaisse	CP II Z 32	14	1,40	2,10	0,50	0	18,80	A
342	Gnaisse	CP II Z 32	28	1,40	2,10	0,50	0	28,51	A
343	Gnaisse	CP II Z 32	28	1,40	2,10	0,50	0	23,09	A
344	Gnaisse	CP II Z 32	28	1,40	2,10	0,50	0	25,60	A
345	Gnaisse	CP II Z 32	28	1,40	2,10	0,50	0	23,51	A
346	Gnaisse	CP II Z 32	56	1,40	2,10	0,50	0	26,10	A
347	Gnaisse	CP II Z 32	56	1,40	2,10	0,50	0	23,44	A
348	Gnaisse	CP II Z 32	56	1,40	2,10	0,50	0	26,33	A
349	Gnaisse	CP II Z 32	56	1,40	2,10	0,50	0	24,79	A
350	Sienito	CP III RS 40	3	1,60	2,50	0,50	3	26,1	A
351	Sienito	CP III RS 40	3	1,60	2,50	0,50	3	28,71	A
352	Sienito	CP III RS 40	3	1,60	2,50	0,50	3	23,49	A
353	Sienito	CP III RS 40	7	1,60	2,50	0,50	3	35,4	A
354	Sienito	CP III RS 40	7	1,60	2,50	0,50	3	38,94	A
355	Sienito	CP III RS 40	7	1,60	2,50	0,50	3	31,86	A
356	Sienito	CP III RS 40	14	1,60	2,50	0,50	3	42,7	A
357	Sienito	CP III RS 40	14	1,60	2,50	0,50	3	46,97	A
358	Sienito	CP III RS 40	14	1,60	2,50	0,50	3	38,43	A
359	Sienito	CP III RS 40	28	1,60	2,50	0,50	3	49,6	A
360	Sienito	CP III RS 40	28	1,60	2,50	0,50	3	54,56	A
361	Sienito	CP III RS 40	28	1,60	2,50	0,50	3	44,64	A
362	Traquito	CP III 32	3	1,41	3,30	0,50	0,58	12	A
363	Traquito	CP III 32	7	1,41	3,30	0,50	0,58	24	A
364	Traquito	CP III 32	14	1,41	3,30	0,50	0,58	24,4	A
365	Traquito	CP III 32	28	1,41	3,30	0,50	0,58	29,7	A
366	Traquito	CP III 32	56	1,41	3,30	0,50	0,58	30,7	A
367	Granulito	CP II F 32	7	2,00	2,66	0,51	0,6	37,12	A
368	Granulito	CP II F 32	7	2,00	2,66	0,51	0,6	37,24	A
369	Granulito	CP II F 32	7	2,00	2,66	0,51	0,6	36,95	A
370	Granulito	CP II F 32	28	2,00	2,66	0,51	0,6	48,76	A
371	Granulito	CP II F 32	28	2,00	2,66	0,51	0,6	48,73	A
372	Granulito	CP II F 32	28	2,00	2,66	0,51	0,6	52,17	A
373	Micaxisto	CP II F 32	7	2,00	2,66	0,51	0,6	28,46	A

374	Micaxisto	CP II F 32	7	2,00	2,66	0,51	0,6	28,61	A
375	Micaxisto	CP II F 32	7	2,00	2,66	0,51	0,6	29,31	A
376	Micaxisto	CP II F 32	28	2,00	2,66	0,51	0,6	32,4	A
377	Micaxisto	CP II F 32	28	2,00	2,66	0,51	0,6	33,12	A
378	Micaxisto	CP II F 32	28	2,00	2,66	0,51	0,6	34,3	A
379	Diabasio	CP II Z 32	7	2,33	3,15	0,52	0	16,71	A
380	Diabasio	CP II Z 32	7	2,33	3,15	0,52	0	17,15	A
381	Diabasio	CP II Z 32	7	2,33	3,15	0,52	0	16,27	A
382	Diabasio	CP II Z 32	28	2,33	3,15	0,52	0	30,85	A
383	Diabasio	CP II Z 32	28	2,33	3,15	0,52	0	32	A
384	Diabasio	CP II Z 32	28	2,33	3,15	0,52	0	29	A
385	Granito	CP III RS 40	28	2,32	3,46	0,52	0,21	40,71	A
386	Granito	CP III RS 40	28	2,32	3,46	0,52	0,21	43,64	A
387	Granito	CP III RS 40	28	2,32	3,46	0,52	0,21	42,36	A
388	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	43,59	A
389	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	42,53	A
390	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	44,74	A
391	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	45,67	A
392	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	42,7	A
393	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	44,78	A
394	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	43,32	A
395	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	44,96	A
396	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	41,32	A
397	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	45,21	A
398	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	42,14	A
399	Granito	CP III RS 40	28	2,33	3,15	0,52	0,21	45,95	A
400	Basalto	CP IV 32	28	2,74	3,06	0,53	0	40,1	A
401	Basalto	CP IV 32	28	2,74	3,06	0,53	0	37,1	A
402	Basalto	CP IV 32	28	2,74	3,06	0,53	0	38,2	A
403	Basalto	CP IV 32	28	2,74	3,06	0,53	0	38,7	A
404	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	22,87	A
405	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	24,5	A
406	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	21,24	A
407	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	31,3	A
408	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	32,88	A
409	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	29,72	A
410	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	26,88	A
411	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	28,55	A
412	Basalto	CP II E 32	7	2,50	3,50	0,53	0,77	25,21	A
413	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	24,44	A
414	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	26,03	A
415	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	22,85	A
416	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	32,4	A
417	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	36,04	A
418	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	28,76	A
419	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	29,69	A
420	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	32,02	A

421	Basalto	CP II E 32	14	2,50	3,50	0,53	0,77	27,36	A
422	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	25,57	A
423	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	27,81	A
424	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	23,33	A
425	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	35,06	A
426	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	36,97	A
427	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	33,15	A
428	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	35,5	A
429	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	36,86	A
430	Basalto	CP II E 32	28	2,50	3,50	0,53	0,77	34,14	A
431	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	26,19	A
432	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	28,31	A
433	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	24,07	A
434	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	37,77	A
435	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	38,83	A
436	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	36,71	A
437	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	36,61	A
438	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	38,5	A
439	Basalto	CP II E 32	56	2,50	3,50	0,53	0,77	34,72	A
440	Calcario	CP IV 32	28	2,74	3,06	0,53	0	36,6	A
441	Calcario	CP IV 32	28	2,74	3,06	0,53	0	35,3	A
442	Calcario	CP IV 32	28	2,74	3,06	0,53	0	35	A
443	Calcario	CP IV 32	28	2,74	3,06	0,53	0	36,8	A
444	Diabasio	CP IV 32	28	2,74	3,06	0,53	0	31,8	A
445	Diabasio	CP IV 32	28	2,74	3,06	0,53	0	32	A
446	Diabasio	CP IV 32	28	2,74	3,06	0,53	0	32,3	A
447	Diabasio	CP IV 32	28	2,74	3,06	0,53	0	32,7	A
448	Dolomito	CP II E 32	7	2,50	3,50	0,53	0,77	25,65	A
449	Dolomito	CP II E 32	7	2,50	3,50	0,53	0,77	27,28	A
450	Dolomito	CP II E 32	7	2,50	3,50	0,53	0,77	24,02	A
451	Dolomito	CP II E 32	14	2,50	3,50	0,53	0,77	28,73	A
452	Dolomito	CP II E 32	14	2,50	3,50	0,53	0,77	30,32	A
453	Dolomito	CP II E 32	14	2,50	3,50	0,53	0,77	27,14	A
454	Dolomito	CP II E 32	28	2,50	3,50	0,53	0,77	29,48	A
455	Dolomito	CP II E 32	28	2,50	3,50	0,53	0,77	31,72	A
456	Dolomito	CP II E 32	28	2,50	3,50	0,53	0,77	27,24	A
457	Dolomito	CP II E 32	56	2,50	3,50	0,53	0,77	29,82	A
458	Dolomito	CP II E 32	56	2,50	3,50	0,53	0,77	31,94	A
459	Dolomito	CP II E 32	56	2,50	3,50	0,53	0,77	27,7	A
460	Gnaisse	CP IV 32	28	2,74	3,06	0,53	0	29,2	A
461	Gnaisse	CP IV 32	28	2,74	3,06	0,53	0	25,8	A
462	Gnaisse	CP IV 32	28	2,74	3,06	0,53	0	27,1	A
463	Gnaisse	CP IV 32	28	2,74	3,06	0,53	0	29	A
464	Granito	CP IV 32	28	2,74	3,06	0,53	0	36,8	A
465	Granito	CP IV 32	28	2,74	3,06	0,53	0	36,9	A
466	Granito	CP IV 32	28	2,74	3,06	0,53	0	37,4	A
467	Granito	CP IV 32	28	2,74	3,06	0,53	0	37,6	A

468	Granito	CP II E 32	28	2,01	3,99	0,53	0	27,92	A
469	Calcario	CP II E 32	3	2,64	3,28	0,54	0	17,8	A
470	Calcario	CP II E 32	3	2,64	3,28	0,54	0	18,4	A
471	Calcario	CP II E 32	3	2,64	3,28	0,54	0	20,7	A
472	Calcario	CP II E 32	3	2,64	3,28	0,54	0	19	A
473	Calcario	CP II E 32	3	2,64	3,28	0,54	0	16,6	A
474	Calcario	CP II E 32	3	2,64	3,28	0,54	0	17,8	A
475	Calcario	CP II E 32	3	2,64	3,28	0,54	0	16,6	A
476	Calcario	CP II E 32	3	2,64	3,28	0,54	0	17,2	A
477	Calcario	CP II E 32	7	2,64	3,28	0,54	0	24,8	A
478	Calcario	CP II E 32	7	2,64	3,28	0,54	0	24,6	A
479	Calcario	CP II E 32	7	2,64	3,28	0,54	0	25,5	A
480	Calcario	CP II E 32	7	2,64	3,28	0,54	0	24,8	A
481	Calcario	CP II E 32	7	2,64	3,28	0,54	0	26,1	A
482	Calcario	CP II E 32	7	2,64	3,28	0,54	0	24,8	A
483	Calcario	CP II E 32	7	2,64	3,28	0,54	0	26,1	A
484	Calcario	CP II E 32	7	2,64	3,28	0,54	0	25,1	A
485	Calcario	CP II E 32	28	2,64	3,28	0,54	0	33,7	A
486	Calcario	CP II E 32	28	2,64	3,28	0,54	0	34,4	A
487	Calcario	CP II E 32	28	2,64	3,28	0,54	0	35,6	A
488	Calcario	CP II E 32	28	2,64	3,28	0,54	0	34,1	A
489	Calcario	CP II E 32	28	2,64	3,28	0,54	0	34,9	A
490	Calcario	CP II E 32	28	2,64	3,28	0,54	0	37	A
491	Calcario	CP II E 32	28	2,64	3,28	0,54	0	36,7	A
492	Calcario	CP II E 32	28	2,64	3,28	0,54	0	34,4	A
493	Granito	CP III RS 40	7	1,86	3,45	0,54	0,57	23,75	A
494	Granito	CP III RS 40	7	1,86	3,45	0,54	0,57	25,85	A
495	Granito	CP III RS 40	7	1,86	3,45	0,54	0,57	26,55	A
496	Granito	CP III RS 40	7	1,86	3,45	0,54	0,57	24,36	A
497	Granito	CP III RS 40	7	1,88	2,71	0,54	0,57	26,16	A
498	Granito	CP III RS 40	7	1,88	2,71	0,54	0,57	24,3	A
499	Granito	CP III RS 40	7	1,88	2,71	0,54	0,57	24,12	A
500	Granito	CP III RS 40	7	1,88	2,71	0,54	0,57	26,41	A
501	Granito	CP III RS 40	7	1,25	3,26	0,54	0,57	26,94	A
502	Granito	CP III RS 40	7	1,25	3,26	0,54	0,57	27,27	A
503	Granito	CP III RS 40	7	1,25	3,26	0,54	0,57	25,33	A
504	Granito	CP III RS 40	7	1,25	3,26	0,54	0,57	25,82	A
505	Granito	CP III RS 40	7	1,25	3,26	0,54	0,57	25,76	A
506	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	35,69	A
507	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	35,73	A
508	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	36,7	A
509	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	36,31	A
510	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	35,84	A
511	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	35,28	A
512	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	38,78	A
513	Granito	CP III RS 40	7	1,25	3,26	0,54	0,6	35,22	A
514	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	36,3	A

515	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	36,33	A
516	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	35,47	A
517	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	35,83	A
518	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	35,51	A
519	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	36,42	A
520	Granito	CP III RS 40	7	2,64	3,28	0,54	0,6	35,9	A
521	Granito	CP III RS 40	28	1,86	3,45	0,54	0,57	33,67	A
522	Granito	CP III RS 40	28	1,86	3,45	0,54	0,57	36,3	A
523	Granito	CP III RS 40	28	1,86	3,45	0,54	0,57	32,49	A
524	Granito	CP III RS 40	28	1,86	3,45	0,54	0,57	32,67	A
525	Granito	CP III RS 40	28	1,88	2,71	0,54	0,57	38,08	A
526	Granito	CP III RS 40	28	1,88	2,71	0,54	0,57	35,59	A
527	Granito	CP III RS 40	28	1,88	2,71	0,54	0,57	37,44	A
528	Granito	CP III RS 40	28	1,88	2,71	0,54	0,57	34,79	A
529	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	35,26	A
530	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	33,98	A
531	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	34,37	A
532	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	34,26	A
533	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	34,79	A
534	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	33,34	A
535	Granito	CP III RS 40	28	1,25	3,26	0,54	0,57	33,61	A
536	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	40,68	A
537	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	41,37	A
538	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	44,49	A
539	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	44,44	A
540	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	41,58	A
541	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	46,1	A
542	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	44,61	A
543	Granito	CP III RS 40	28	1,25	3,26	0,54	0,6	45,85	A
544	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	41,96	A
545	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	46,1	A
546	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	46,09	A
547	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	45,99	A
548	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	42,2	A
549	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	43,77	A
550	Granito	CP III RS 40	28	2,64	3,28	0,54	0,6	46,03	A
551	Granito	CP III RS 40	56	1,86	3,45	0,54	0,57	42,5	A
552	Granito	CP III RS 40	56	1,86	3,45	0,54	0,57	44,92	A
553	Granito	CP III RS 40	56	1,86	3,45	0,54	0,57	43,77	A
554	Granito	CP III RS 40	56	1,86	3,45	0,54	0,57	43,58	A
555	Granito	CP III RS 40	56	1,88	2,71	0,54	0,57	40,08	A
556	Granito	CP III RS 40	56	1,88	2,71	0,54	0,57	38,89	A
557	Granito	CP III RS 40	56	1,88	2,71	0,54	0,57	41,48	A
558	Granito	CP III RS 40	56	1,88	2,71	0,54	0,57	40,38	A
559	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	42,63	A
560	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	41,11	A
561	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	40,51	A

562	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	41,41	A
563	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	43,9	A
564	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	42,09	A
565	Granito	CP III RS 40	56	1,25	3,26	0,54	0,57	44,64	A
566	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	42,33	A
567	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	42,33	A
568	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	42,52	A
569	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	44,82	A
570	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	47,45	A
571	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	44,14	A
572	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	48,28	A
573	Granito	CP III RS 40	56	1,25	3,26	0,54	0,6	47,19	A
574	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	45,9	A
575	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	42,14	A
576	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	8,39	A
577	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	45,55	A
578	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	47,31	A
579	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	42,55	A
580	Granito	CP III RS 40	56	2,64	3,28	0,54	0,6	48,56	A
581	Basalto	CP IV 32	7	2,15	2,79	0,55	0	22	B
582	Basalto	CP IV 32	14	2,15	2,79	0,55	0	24	B
583	Basalto	CP IV 32	28	2,15	2,79	0,55	0	30	B
584	Basalto	CP V ARI	7	2,15	2,79	0,55	0	31	B
585	Basalto	CP V ARI	14	2,15	2,79	0,55	0	34	B
586	Basalto	CP V ARI	28	2,15	2,79	0,55	0	31	B
587	Basalto	CP II F 40	3	2,70	3,02	0,55	1,35	20,5	B
588	Basalto	CP II F 40	3	2,43	2,99	0,55	0,68	23,3	B
589	Basalto	CP II F 40	7	2,70	3,02	0,55	1,35	27,5	B
590	Basalto	CP II F 40	7	2,43	2,99	0,55	0,68	32,3	B
591	Basalto	CP II F 40	28	2,70	3,02	0,55	1,35	39	B
592	Basalto	CP II F 40	28	2,43	2,99	0,55	0,68	45,9	B
593	Gnaïsse	CP III 32	3	2,15	2,79	0,55	0,5	15,5	B
594	Gnaïsse	CP III 32	7	2,15	2,79	0,55	0,5	18,8	B
595	Gnaïsse	CP III 32	14	2,15	2,79	0,55	0,5	27,6	B
596	Gnaïsse	CP III 32	28	2,15	2,79	0,55	0,5	29	B
597	Gnaïsse	CP III 32	56	2,15	2,79	0,55	0,5	29,7	B
598	Gnaïsse	CP III RS 40	3	2,43	2,99	0,55	0,35	15,8	B
599	Gnaïsse	CP III RS 40	3	2,43	2,99	0,55	0,35	17,38	B
600	Gnaïsse	CP III RS 40	3	2,72	2,51	0,55	0,35	14,22	B
601	Gnaïsse	CP III RS 40	3	1,56	2,96	0,55	3	20,1	B
602	Gnaïsse	CP III RS 40	3	0,92	2,08	0,55	3	22,11	B
603	Gnaïsse	CP III RS 40	3	1,40	2,60	0,55	3	18,09	B
604	Gnaïsse	CP III RS 40	7	2,43	2,99	0,55	0,35	28,5	B
605	Gnaïsse	CP III RS 40	7	2,43	2,99	0,55	0,35	31,35	B
606	Gnaïsse	CP III RS 40	7	2,72	2,51	0,55	0,35	25,65	B
607	Gnaïsse	CP III RS 40	7	1,56	2,96	0,55	3	30,7	B
608	Gnaïsse	CP III RS 40	7	0,92	2,08	0,55	3	33,77	B

609	Gnaisse	CP III RS 40	7	1,40	2,60	0,55	3	27,63	B
610	Gnaisse	CP III RS 40	14	2,43	2,99	0,55	0,35	33,1	B
611	Gnaisse	CP III RS 40	14	2,43	2,99	0,55	0,35	36,41	B
612	Gnaisse	CP III RS 40	14	2,72	2,51	0,55	0,35	29,79	B
613	Gnaisse	CP III RS 40	14	1,56	2,96	0,55	3	36,4	B
614	Gnaisse	CP III RS 40	14	0,92	2,08	0,55	3	40,04	B
615	Gnaisse	CP III RS 40	14	1,40	2,60	0,55	3	32,76	B
616	Gnaisse	CP III RS 40	28	2,43	2,99	0,55	0,35	35	B
617	Gnaisse	CP III RS 40	28	2,43	2,99	0,55	0,35	38,5	B
618	Gnaisse	CP III RS 40	28	2,72	2,51	0,55	0,35	31,5	B
619	Gnaisse	CP III RS 40	28	1,56	2,96	0,55	3	40,7	B
620	Gnaisse	CP III RS 40	28	0,92	2,08	0,55	3	44,77	B
621	Gnaisse	CP III RS 40	28	1,40	2,60	0,55	3	36,63	B
622	Gnaisse	CP V ARI	3	2,70	3,02	0,55	0,44	30,4	B
623	Gnaisse	CP V ARI	7	2,70	3,02	0,55	0,44	31,5	B
624	Gnaisse	CP V ARI	14	2,70	3,02	0,55	0,44	34,1	B
625	Gnaisse	CP V ARI	28	2,70	3,02	0,55	0,44	34,5	B
626	Gnaisse	CP V ARI	56	2,70	3,02	0,55	0,44	42,7	B
627	Gnaisse	CP II E 32	28	2,36	3,74	0,55	0	25	B
628	Granito	CP III RS 40	28	1,88	3,12	0,55	0,6	32,59	B
629	Granito	CP III RS 40	28	0,92	2,08	0,55	0,6	35,51	B
630	Granito	CP III RS 40	28	1,40	2,60	0,55	0,6	34,49	B
631	Granito	CP III RS 40	28	1,88	3,12	0,55	0,6	32,18	B
632	Granito	CP III RS 40	28	1,50	1,50	0,55	0,6	35,34	B
633	Granito	CP III RS 40	28	2,00	2,00	0,55	0,6	31,34	B
634	Granito	CP III RS 40	28	2,50	2,50	0,55	0,6	33,98	B
635	Granito	CP III RS 40	28	1,50	1,50	0,55	0,6	33,55	B
636	Granito	CP III RS 40	28	2,00	2,00	0,55	0,6	33,67	B
637	Granito	CP III RS 40	28	2,50	2,50	0,55	0,6	34,45	B
638	Granito	CP III RS 40	28	2,42	3,28	0,55	0,6	34,34	B
639	Granito	CP III RS 40	28	2,62	3,20	0,55	0,6	33,6	B
640	Granito	CP III RS 40	28	2,42	3,28	0,55	0,6	34,55	B
641	Granito	CP III RS 40	28	2,36	3,74	0,55	0,6	33,15	B
642	Granito	CP III RS 40	28	2,36	3,74	0,55	0,6	35,09	B
643	Seixo lavado	CP II Z 32	7	2,36	3,74	0,55	0	15,28	B
644	Seixo lavado	CP II Z 32	7	2,36	3,74	0,55	0	15,9	B
645	Seixo lavado	CP II Z 32	7	2,36	3,74	0,55	0	13,53	B
646	Seixo lavado	CP II Z 32	7	2,36	3,74	0,55	0	15,22	B
647	Seixo lavado	CP II Z 32	7	2,36	3,74	0,55	0	12,74	B
648	Seixo lavado	CP II Z 32	7	2,36	3,74	0,55	0	10,64	B
649	Seixo lavado	CP II Z 32	28	2,36	3,74	0,55	0	17,17	B
650	Seixo lavado	CP II Z 32	28	2,36	3,74	0,55	0	16,67	B
651	Seixo lavado	CP II Z 32	28	2,36	3,74	0,55	0	12	B
652	Seixo lavado	CP II Z 32	28	2,36	3,74	0,55	0	17,88	B
653	Seixo lavado	CP II Z 32	28	2,36	3,74	0,55	0	15,72	B
654	Seixo lavado	CP II Z 32	28	2,36	3,74	0,55	0	13,53	B
655	Seixo misto	CP II Z 32	7	2,36	3,74	0,55	0	15,39	B

656	Seixo misto	CP II Z 32	7	2,36	3,74	0,55	0	18,53	B
657	Seixo misto	CP II Z 32	7	2,36	3,74	0,55	0	11,73	B
658	Seixo misto	CP II Z 32	7	2,36	3,74	0,55	0	14,98	B
659	Seixo misto	CP II Z 32	7	2,36	3,74	0,55	0	19,27	B
660	Seixo misto	CP II Z 32	7	2,36	3,74	0,55	0	12,74	B
661	Seixo misto	CP II Z 32	28	2,36	3,74	0,55	0	18,02	B
662	Seixo misto	CP II Z 32	28	2,36	3,74	0,55	0	20,45	B
663	Seixo misto	CP II Z 32	28	2,36	3,74	0,55	0	16,49	B
664	Seixo misto	CP II Z 32	28	2,36	3,74	0,55	0	18,94	B
665	Seixo misto	CP II Z 32	28	2,36	3,74	0,55	0	19,5	B
666	Seixo misto	CP II Z 32	28	2,36	3,74	0,55	0	13,71	B
667	Sienito	CP III RS 40	3	2,56	2,80	0,55	3	22,6	B
668	Sienito	CP III RS 40	3	2,75	2,83	0,55	3	24,86	B
669	Sienito	CP III RS 40	3	1,46	2,96	0,55	3	20,34	B
670	Sienito	CP III RS 40	7	2,56	2,80	0,55	3	33,4	B
671	Sienito	CP III RS 40	7	2,75	2,83	0,55	3	36,74	B
672	Sienito	CP III RS 40	7	1,46	2,96	0,55	3	30,06	B
673	Sienito	CP III RS 40	14	2,56	2,80	0,55	3	38,3	B
674	Sienito	CP III RS 40	14	2,75	2,83	0,55	3	42,13	B
675	Sienito	CP III RS 40	14	1,46	2,96	0,55	3	34,47	B
676	Sienito	CP III RS 40	28	2,56	2,80	0,55	3	44,3	B
677	Sienito	CP III RS 40	28	2,75	2,83	0,55	3	48,73	B
678	Sienito	CP III RS 40	28	1,46	2,96	0,55	3	39,87	B
679	Traquito	CP III 32	3	2,70	3,02	0,55	0,52	9,8	B
680	Traquito	CP III 32	7	2,70	3,02	0,55	0,52	22,3	B
681	Traquito	CP III 32	14	2,70	3,02	0,55	0,52	28,9	B
682	Traquito	CP III 32	28	2,70	3,02	0,55	0,52	29,2	B
683	Traquito	CP III 32	56	2,70	3,02	0,55	0,52	31,6	B
684	Basalto	CP V ARI	28	0,92	2,08	0,57	0	47,02	B
685	Basalto	CP V ARI	28	1,40	2,60	0,57	0	46,02	B
686	Basalto	CP V ARI	28	1,88	3,12	0,57	0	48,02	B
687	Calcario	CP V ARI	28	1,50	1,50	0,57	0	44,48	B
688	Calcario	CP V ARI	28	2,00	2,00	0,57	0	43,48	B
689	Calcario	CP V ARI	28	2,50	2,50	0,57	0	45,48	B
690	Gnaisse	CP I S 32	28	2,80	2,39	0,57	0	25	B
691	Granito	CP III RS 40	3	2,80	2,39	0,57	0	12	B
692	Granito	CP III RS 40	3	2,80	2,39	0,57	0	13,2	B
693	Granito	CP III RS 40	3	2,67	2,32	0,57	0	10,8	B
694	Granito	CP III RS 40	7	2,80	2,39	0,57	0	18	B
695	Granito	CP III RS 40	7	2,80	2,39	0,57	0	19,8	B
696	Granito	CP III RS 40	7	2,67	2,32	0,57	0	16,2	B
697	Granito	CP III RS 40	28	2,80	2,39	0,57	0	26	B
698	Granito	CP III RS 40	28	2,80	2,39	0,57	0	28,6	B
699	Granito	CP III RS 40	28	2,67	2,32	0,57	0	23,4	B
700	Granito	CP IV 32	3	2,67	2,32	0,57	0	15	B
701	Granito	CP IV 32	3	2,67	2,32	0,57	0	16,5	B
702	Granito	CP IV 32	3	3,29	2,80	0,57	0	13,5	B

703	Granito	CP IV 32	7	2,67	2,32	0,57	0	19	B
704	Granito	CP IV 32	7	2,67	2,32	0,57	0	20,9	B
705	Granito	CP IV 32	7	3,29	2,80	0,57	0	17,1	B
706	Granito	CP IV 32	28	2,67	2,32	0,57	0	24	B
707	Granito	CP IV 32	28	2,67	2,32	0,57	0	26,4	B
708	Granito	CP IV 32	28	3,29	2,80	0,57	0	21,6	B
709	Granito	CP II F 32	3	0,92	2,08	0,57	0	12	B
710	Granito	CP II F 32	3	1,40	2,60	0,57	0	13,2	B
711	Granito	CP II F 32	3	1,88	3,12	0,57	0	10,8	B
712	Granito	CP II F 32	7	0,92	2,08	0,57	0	16	B
713	Granito	CP II F 32	7	1,40	2,60	0,57	0	17,6	B
714	Granito	CP II F 32	7	1,88	3,12	0,57	0	14,4	B
715	Granito	CP II F 32	28	0,92	2,08	0,57	0	25	B
716	Granito	CP II F 32	28	1,40	2,60	0,57	0	27,5	B
717	Granito	CP II F 32	28	1,88	3,12	0,57	0	22,5	B
718	Seixo lavado	CP II Z 32	7	1,50	1,50	0,57	0	14,72	B
719	Seixo lavado	CP II Z 32	7	2,00	2,00	0,57	0	13,98	B
720	Seixo lavado	CP II Z 32	7	2,50	2,50	0,57	0	13,12	B
721	Seixo lavado	CP II Z 32	7	2,00	3,00	0,57	0	15,69	B
722	Seixo lavado	CP II Z 32	7	2,00	3,00	0,57	0	13,65	B
723	Seixo lavado	CP II Z 32	7	2,00	3,00	0,57	0	10,55	B
724	Seixo lavado	CP II Z 32	28	1,50	1,50	0,57	0	17,43	B
725	Seixo lavado	CP II Z 32	28	2,00	2,00	0,57	0	16,46	B
726	Seixo lavado	CP II Z 32	28	2,50	2,50	0,57	0	14,57	B
727	Seixo lavado	CP II Z 32	28	2,00	3,00	0,57	0	20,89	B
728	Seixo lavado	CP II Z 32	28	2,00	3,00	0,57	0	14,98	B
729	Seixo lavado	CP II Z 32	28	2,00	3,00	0,57	0	14,42	B
730	Seixo misto	CP II Z 32	7	2,00	3,00	0,57	0	12,59	B
731	Seixo misto	CP II Z 32	7	2,00	3,00	0,57	0	15,51	B
732	Seixo misto	CP II Z 32	7	2,00	3,00	0,57	0	14,45	B
733	Seixo misto	CP II Z 32	7	2,00	3,00	0,57	0	10,08	B
734	Seixo misto	CP II Z 32	7	2,00	3,00	0,57	0	15,31	B
735	Seixo misto	CP II Z 32	7	2,00	3,00	0,57	0	14,33	B
736	Seixo misto	CP II Z 32	28	2,00	3,00	0,57	0	17,05	B
737	Seixo misto	CP II Z 32	28	2,00	3,00	0,57	0	17,08	B
738	Seixo misto	CP II Z 32	28	2,00	3,00	0,57	0	13,83	B
739	Seixo misto	CP II Z 32	28	2,00	3,00	0,57	0	17,85	B
740	Seixo misto	CP II Z 32	28	2,00	3,00	0,57	0	21,07	B
741	Seixo misto	CP II Z 32	28	2,00	3,00	0,57	0	18,05	B
742	Calcario	CP II F 32	3	2,32	2,04	0,58	0	16,55	B
743	Calcario	CP II F 32	3	2,32	2,04	0,58	0	17,02	B
744	Calcario	CP II F 32	3	2,32	2,04	0,58	0	17,03	B
745	Calcario	CP II F 32	7	2,32	2,04	0,58	0	20,05	B
746	Calcario	CP II F 32	7	2,32	2,04	0,58	0	20,49	B
747	Calcario	CP II F 32	7	2,32	2,04	0,58	0	21,8	B
748	Calcario	CP II F 32	14	2,32	2,04	0,58	0	22,79	B
749	Calcario	CP II F 32	14	2,32	2,04	0,58	0	23,02	B

750	Calcario	CP II F 32	14	2,32	2,04	0,58	0	25,06	B
751	Calcario	CP II F 32	28	2,32	2,04	0,58	0	24,52	B
752	Calcario	CP II F 32	28	2,32	2,04	0,58	0	25,52	B
753	Calcario	CP II F 32	28	2,32	2,04	0,58	0	25,02	B
754	Gnaïsse	CP II E 32	3	2,32	2,04	0,58	0	16	B
755	Gnaïsse	CP II E 32	3	2,32	2,04	0,58	0	14	B
756	Gnaïsse	CP II E 32	3	2,32	2,04	0,58	0	15,3	B
757	Gnaïsse	CP II E 32	7	2,32	2,04	0,58	0	18	B
758	Gnaïsse	CP II E 32	7	2,32	2,04	0,58	0	19	B
759	Gnaïsse	CP II E 32	7	2,32	2,04	0,58	0	17,5	B
760	Gnaïsse	CP II E 32	14	2,32	2,04	0,58	0	24,8	B
761	Gnaïsse	CP II E 32	14	2,32	2,04	0,58	0	24	B
762	Gnaïsse	CP II E 32	14	2,32	2,04	0,58	0	22,5	B
763	Gnaïsse	CP II E 32	28	2,32	2,04	0,58	0	27,5	B
764	Gnaïsse	CP II E 32	28	2,32	2,04	0,58	0	24,6	B
765	Gnaïsse	CP II E 32	28	2,32	2,04	0,58	0	32,5	B
766	Granito	CP II F 32	28	2,36	2,40	0,58	0,6	33,25	B
767	Granito	CP II F 32	28	2,36	2,40	0,58	0,6	30,57	B
768	Granito	CP II F 32	28	2,36	2,40	0,58	0,6	30,71	B
769	Granito	CP II F 32	28	1,86	2,64	0,58	0,6	31,18	B
770	Granito	CP II F 32	28	1,86	2,64	0,58	0,6	29,93	B
771	Granito	CP II F 32	28	1,86	2,64	0,58	0,6	26,96	B
772	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	30,65	B
773	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	30,71	B
774	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,88	B
775	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	29,27	B
776	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	30,36	B
777	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	31,73	B
778	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,51	B
779	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	30,76	B
780	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	33,45	B
781	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	32,54	B
782	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	35,74	B
783	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	26,71	B
784	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	29,87	B
785	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	29,18	B
786	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	30,31	B
787	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,09	B
788	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,73	B
789	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,21	B
790	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,16	B
791	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,9	B
792	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,74	B
793	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	26,82	B
794	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,74	B
795	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,86	B
796	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	29,55	B

797	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,01	B
798	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	31,19	B
799	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	31,2	B
800	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	27,38	B
801	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	33,1	B
802	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,24	B
803	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	28,32	B
804	Granito	CP II F 32	28	2,32	2,04	0,58	0,6	29,37	B
805	Basalto	CP II F 40	3	2,87	3,04	0,59	1,39	16,3	B
806	Basalto	CP II F 40	7	2,87	3,04	0,59	1,39	23,1	B
807	Basalto	CP II F 40	28	2,87	3,04	0,59	1,39	32,5	B
808	Basalto	CP II Z 32	7	2,66	3,80	0,59	0	21,7	B
809	Basalto	CP II Z 32	7	2,66	3,80	0,59	0	22,7	B
810	Basalto	CP II Z 32	7	2,66	3,80	0,59	0	23,7	B
811	Basalto	CP II Z 32	28	2,66	3,80	0,59	0	26	B
812	Basalto	CP II Z 32	28	2,66	3,80	0,59	0	27	B
813	Basalto	CP II Z 32	28	2,66	3,80	0,59	0	28	B
814	Basalto	CP III RS 40	3	2,52	3,33	0,60	0,81	13,71	B
815	Basalto	CP III RS 40	3	2,52	3,33	0,60	0,81	14,6	B
816	Basalto	CP III RS 40	3	2,52	3,33	0,60	0,81	13,71	B
817	Basalto	CP III RS 40	3	2,52	3,33	0,60	0,81	14,84	B
818	Basalto	CP III RS 40	3	2,52	3,33	0,60	0,81	14	B
819	Basalto	CP III RS 40	3	2,52	3,33	0,60	0,81	14,86	B
820	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	25,28	B
821	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	24,94	B
822	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	24,65	B
823	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	25,25	B
824	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	25,49	B
825	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	24,43	B
826	Basalto	CP III RS 40	14	2,52	3,33	0,60	0,81	39,49	B
827	Basalto	CP III RS 40	14	2,52	3,33	0,60	0,81	30,43	B
828	Basalto	CP III RS 40	14	2,52	3,33	0,60	0,81	28,15	B
829	Basalto	CP III RS 40	14	2,52	3,33	0,60	0,81	30,19	B
830	Basalto	CP III RS 40	14	2,52	3,33	0,60	0,81	31,43	B
831	Basalto	CP III RS 40	14	2,52	3,33	0,60	0,81	33,8	B
832	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	34,18	B
833	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	31,08	B
834	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	31	B
835	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	34,94	B
836	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	31,01	B
837	Basalto	CP III RS 40	28	2,52	3,33	0,60	0,81	33,54	B
838	Basalto	CP V ARI	28	2,57	3,34	0,60	0	32,8	B
839	Basalto	CP V ARI	28	2,57	3,34	0,60	0	34,1	B
840	Basalto	CP V ARI	28	2,57	3,34	0,60	0	35,4	B
841	Basalto	CP V ARI	28	2,57	3,34	0,60	0	42,1	B
842	Basalto	CP V ARI	28	2,57	3,34	0,60	0	35,3	B
843	Basalto	CP V ARI	28	2,57	3,34	0,60	0	42,6	B

844	Basalto	CP II E 32	28	2,91	3,47	0,60	0	20	B
845	Basalto	CP II E 32	28	2,91	3,47	0,60	0	21	B
846	Basalto	CP II E 32	28	2,91	3,47	0,60	0	22	B
847	Basalto	CP II F 32	7	2,45	3,06	0,60	0,6	25,81	B
848	Basalto	CP II F 32	7	2,45	3,06	0,60	0,6	26,49	B
849	Basalto	CP II F 32	7	2,45	3,06	0,60	0,6	29,3	B
850	Basalto	CP II F 32	28	2,45	3,06	0,60	0,6	33,2	B
851	Basalto	CP II F 32	28	2,45	3,06	0,60	0,6	35,38	B
852	Basalto	CP II F 32	28	2,45	3,06	0,60	0,6	36,6	B
853	Calcario	CP III RS 40	3	3,04	3,27	0,60	0,81	12,62	B
854	Calcario	CP III RS 40	3	3,04	3,27	0,60	0,81	12,85	B
855	Calcario	CP III RS 40	3	3,04	3,27	0,60	0,81	12,82	B
856	Calcario	CP III RS 40	3	2,76	3,24	0,60	0,81	12,83	B
857	Calcario	CP III RS 40	3	2,76	3,24	0,60	0,81	13,79	B
858	Calcario	CP III RS 40	3	2,76	3,24	0,60	0,81	13,17	B
859	Calcario	CP III RS 40	3	2,65	3,26	0,60	0,81	13,29	B
860	Calcario	CP III RS 40	3	2,65	3,26	0,60	0,81	13,41	B
861	Calcario	CP III RS 40	3	2,65	3,26	0,60	0,81	13,83	B
862	Calcario	CP III RS 40	3	2,65	3,26	0,60	0,81	15,09	B
863	Calcario	CP III RS 40	3	2,65	3,26	0,60	0,81	13,59	B
864	Calcario	CP III RS 40	3	2,65	3,26	0,60	0,81	11,65	B
865	Calcario	CP III RS 40	7	3,04	3,27	0,60	0,81	25,57	B
866	Calcario	CP III RS 40	7	3,04	3,27	0,60	0,81	24,86	B
867	Calcario	CP III RS 40	7	3,04	3,27	0,60	0,81	25,65	B
868	Calcario	CP III RS 40	7	2,76	3,24	0,60	0,81	27,56	B
869	Calcario	CP III RS 40	7	2,76	3,24	0,60	0,81	28,19	B
870	Calcario	CP III RS 40	7	2,76	3,24	0,60	0,81	29,55	B
871	Calcario	CP III RS 40	7	2,65	3,26	0,60	0,81	25,76	B
872	Calcario	CP III RS 40	7	2,65	3,26	0,60	0,81	27,1	B
873	Calcario	CP III RS 40	7	2,65	3,26	0,60	0,81	23,96	B
874	Calcario	CP III RS 40	7	2,65	3,26	0,60	0,81	26,45	B
875	Calcario	CP III RS 40	7	2,65	3,26	0,60	0,81	26,96	B
876	Calcario	CP III RS 40	7	2,65	3,26	0,60	0,81	26,27	B
877	Calcario	CP III RS 40	14	3,04	3,27	0,60	0,81	32,3	B
878	Calcario	CP III RS 40	14	3,04	3,27	0,60	0,81	31,25	B
879	Calcario	CP III RS 40	14	3,04	3,27	0,60	0,81	31,8	B
880	Calcario	CP III RS 40	14	2,76	3,24	0,60	0,81	34,8	B
881	Calcario	CP III RS 40	14	2,76	3,24	0,60	0,81	30,66	B
882	Calcario	CP III RS 40	14	2,76	3,24	0,60	0,81	33,43	B
883	Calcario	CP III RS 40	14	2,65	3,26	0,60	0,81	28,51	B
884	Calcario	CP III RS 40	14	2,65	3,26	0,60	0,81	24,24	B
885	Calcario	CP III RS 40	14	2,65	3,26	0,60	0,81	26,44	B
886	Calcario	CP III RS 40	14	2,65	3,26	0,60	0,81	29,09	B
887	Calcario	CP III RS 40	14	2,65	3,26	0,60	0,81	30,85	B
888	Calcario	CP III RS 40	14	2,65	3,26	0,60	0,81	27,36	B
889	Calcario	CP III RS 40	28	3,04	3,27	0,60	0,81	35,49	B
890	Calcario	CP III RS 40	28	3,04	3,27	0,60	0,81	31,69	B

891	Calcario	CP III RS 40	28	3,04	3,27	0,60	0,81	34,43	B
892	Calcario	CP III RS 40	28	2,76	3,24	0,60	0,81	35,11	B
893	Calcario	CP III RS 40	28	2,76	3,24	0,60	0,81	34,36	B
894	Calcario	CP III RS 40	28	2,76	3,24	0,60	0,81	36,34	B
895	Calcario	CP III RS 40	28	2,65	3,26	0,60	0,81	34,43	B
896	Calcario	CP III RS 40	28	2,65	3,26	0,60	0,81	34,7	B
897	Calcario	CP III RS 40	28	2,65	3,26	0,60	0,81	31,48	B
898	Calcario	CP III RS 40	28	2,65	3,26	0,60	0,81	36,29	B
899	Calcario	CP III RS 40	28	2,65	3,26	0,60	0,81	34,67	B
900	Calcario	CP III RS 40	28	2,65	3,26	0,60	0,81	31,82	B
901	Dolomito	CP III RS 40	3	2,46	3,41	0,60	0,81	12,19	B
902	Dolomito	CP III RS 40	3	2,46	3,41	0,60	0,81	11,74	B
903	Dolomito	CP III RS 40	3	2,46	3,41	0,60	0,81	12,05	B
904	Dolomito	CP III RS 40	3	2,46	3,41	0,60	0,81	12,85	B
905	Dolomito	CP III RS 40	3	2,46	3,41	0,60	0,81	12,79	B
906	Dolomito	CP III RS 40	3	2,46	3,41	0,60	0,81	12,85	B
907	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	27,41	B
908	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	26,36	B
909	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	30,91	B
910	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	31,24	B
911	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	29,49	B
912	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	27,31	B
913	Dolomito	CP III RS 40	14	2,46	3,41	0,60	0,81	39,34	B
914	Dolomito	CP III RS 40	14	2,46	3,41	0,60	0,81	39,2	B
915	Dolomito	CP III RS 40	14	2,46	3,41	0,60	0,81	36,44	B
916	Dolomito	CP III RS 40	14	2,46	3,41	0,60	0,81	37,58	B
917	Dolomito	CP III RS 40	14	2,46	3,41	0,60	0,81	41,32	B
918	Dolomito	CP III RS 40	14	2,46	3,41	0,60	0,81	37,71	B
919	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	37,57	B
920	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	40,57	B
921	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	35,78	B
922	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	41,31	B
923	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	41,61	B
924	Dolomito	CP III RS 40	28	2,46	3,41	0,60	0,81	39,46	B
925	Gnaisse	CP III 32	3	2,27	3,12	0,60	0,4	11,9	B
926	Gnaisse	CP III 32	28	2,27	3,12	0,60	0,4	15,9	B
927	Gnaisse	CP III 32	14	2,27	3,12	0,60	0,4	21	B
928	Gnaisse	CP III 32	28	2,27	3,12	0,60	0,4	29	B
929	Gnaisse	CP III 32	56	2,27	3,12	0,60	0,4	33,6	B
930	Gnaisse	CP III RS 40	3	2,44	3,42	0,60	0,81	10,52	B
931	Gnaisse	CP III RS 40	3	2,44	3,42	0,60	0,81	9,35	B
932	Gnaisse	CP III RS 40	3	2,44	3,42	0,60	0,81	8,5	B
933	Gnaisse	CP III RS 40	3	2,44	3,42	0,60	0,81	10,74	B
934	Gnaisse	CP III RS 40	3	2,44	3,42	0,60	0,81	9,65	B
935	Gnaisse	CP III RS 40	3	2,44	3,42	0,60	0,81	10,01	B
936	Gnaisse	CP III RS 40	3	2,48	3,38	0,60	0,81	7,8	B
937	Gnaisse	CP III RS 40	3	2,48	3,38	0,60	0,81	8,41	B

938	Gnaïsse	CP III RS 40	3	2,48	3,38	0,60	0,81	9,33	B
939	Gnaïsse	CP III RS 40	3	2,48	3,38	0,60	0,81	9,23	B
940	Gnaïsse	CP III RS 40	3	2,48	3,38	0,60	0,81	9,34	B
941	Gnaïsse	CP III RS 40	3	2,48	3,38	0,60	0,81	8,92	B
942	Gnaïsse	CP III RS 40	7	2,44	3,42	0,60	0,81	22,3	B
943	Gnaïsse	CP III RS 40	7	2,44	3,42	0,60	0,81	23,79	B
944	Gnaïsse	CP III RS 40	7	2,44	3,42	0,60	0,81	23,87	B
945	Gnaïsse	CP III RS 40	7	2,44	3,42	0,60	0,81	26,04	B
946	Gnaïsse	CP III RS 40	7	2,44	3,42	0,60	0,81	25,38	B
947	Gnaïsse	CP III RS 40	7	2,44	3,42	0,60	0,81	24,73	B
948	Gnaïsse	CP III RS 40	7	2,48	3,38	0,60	0,81	28,25	B
949	Gnaïsse	CP III RS 40	7	2,48	3,38	0,60	0,81	24,96	B
950	Gnaïsse	CP III RS 40	7	2,48	3,38	0,60	0,81	27,47	B
951	Gnaïsse	CP III RS 40	7	2,48	3,38	0,60	0,81	26,88	B
952	Gnaïsse	CP III RS 40	7	2,48	3,38	0,60	0,81	23,61	B
953	Gnaïsse	CP III RS 40	7	2,48	3,38	0,60	0,81	23,51	B
954	Gnaïsse	CP III RS 40	14	2,44	3,42	0,60	0,81	32,83	B
955	Gnaïsse	CP III RS 40	14	2,44	3,42	0,60	0,81	31,07	B
956	Gnaïsse	CP III RS 40	14	2,44	3,42	0,60	0,81	27,15	B
957	Gnaïsse	CP III RS 40	14	2,44	3,42	0,60	0,81	32,72	B
958	Gnaïsse	CP III RS 40	14	2,44	3,42	0,60	0,81	32,77	B
959	Gnaïsse	CP III RS 40	14	2,44	3,42	0,60	0,81	32	B
960	Gnaïsse	CP III RS 40	14	2,48	3,38	0,60	0,81	34,15	B
961	Gnaïsse	CP III RS 40	14	2,48	3,38	0,60	0,81	33,48	B
962	Gnaïsse	CP III RS 40	14	2,48	3,38	0,60	0,81	37,88	B
963	Gnaïsse	CP III RS 40	14	2,48	3,38	0,60	0,81	36,6	B
964	Gnaïsse	CP III RS 40	14	2,48	3,38	0,60	0,81	31,48	B
965	Gnaïsse	CP III RS 40	14	2,48	3,38	0,60	0,81	34,01	B
966	Gnaïsse	CP III RS 40	28	2,44	3,42	0,60	0,81	33,6	B
967	Gnaïsse	CP III RS 40	28	2,44	3,42	0,60	0,81	27,4	B
968	Gnaïsse	CP III RS 40	28	2,44	3,42	0,60	0,81	33,88	B
969	Gnaïsse	CP III RS 40	28	2,44	3,42	0,60	0,81	34,3	B
970	Gnaïsse	CP III RS 40	28	2,44	3,42	0,60	0,81	33,22	B
971	Gnaïsse	CP III RS 40	28	2,44	3,42	0,60	0,81	35,14	B
972	Gnaïsse	CP III RS 40	28	2,48	3,38	0,60	0,81	35,98	B
973	Gnaïsse	CP III RS 40	28	2,48	3,38	0,60	0,81	36,12	B
974	Gnaïsse	CP III RS 40	28	2,48	3,38	0,60	0,81	40,57	B
975	Gnaïsse	CP III RS 40	28	2,48	3,38	0,60	0,81	43,18	B
976	Gnaïsse	CP III RS 40	28	2,48	3,38	0,60	0,81	41,258	B
977	Gnaïsse	CP III RS 40	28	2,48	3,38	0,60	0,81	41,12	B
978	Gnaïsse	CP III RS 40	3	1,40	2,10	0,60	0,35	14,9	B
979	Gnaïsse	CP III RS 40	3	1,40	2,10	0,60	0,35	16,39	B
980	Gnaïsse	CP III RS 40	3	1,40	2,10	0,60	0,35	13,41	B
981	Gnaïsse	CP III RS 40	28	1,40	2,10	0,60	0	19	B
982	Gnaïsse	CP III RS 40	28	1,40	2,10	0,60	0	26	B
983	Gnaïsse	CP III RS 40	28	1,40	2,10	0,60	0	32	B
984	Gnaïsse	CP III RS 40	28	1,40	2,10	0,60	0,35	27,9	B

985	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0,35	30,69	B
986	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0,35	25,11	B
987	Gnaisse	CP III RS 40	14	1,40	2,10	0,60	0,35	30,8	B
988	Gnaisse	CP III RS 40	14	1,40	2,10	0,60	0,35	33,88	B
989	Gnaisse	CP III RS 40	14	1,40	2,10	0,60	0,35	27,72	B
990	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0	27	B
991	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0	33	B
992	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0	45	B
993	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0,35	33,6	B
994	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0,35	36,96	B
995	Gnaisse	CP III RS 40	28	1,40	2,10	0,60	0,35	30,24	B
996	Gnaisse	CP III RS 40	3	2,53	3,13	0,60	3	16,7	B
997	Gnaisse	CP III RS 40	3	2,53	3,13	0,60	3	18,37	B
998	Gnaisse	CP III RS 40	3	2,53	3,13	0,60	3	15,03	B
999	Gnaisse	CP III RS 40	7	2,53	3,13	0,60	3	27,5	B
1000	Gnaisse	CP III RS 40	7	2,53	3,13	0,60	3	30,25	B
1001	Gnaisse	CP III RS 40	7	2,53	3,13	0,60	3	24,75	B
1002	Gnaisse	CP III RS 40	14	2,53	3,13	0,60	3	30,5	B
1003	Gnaisse	CP III RS 40	14	2,53	3,13	0,60	3	33,55	B
1004	Gnaisse	CP III RS 40	14	2,53	3,13	0,60	3	27,45	B
1005	Gnaisse	CP III RS 40	28	2,53	3,13	0,60	3	36,5	B
1006	Gnaisse	CP III RS 40	28	2,53	3,13	0,60	3	40,15	B
1007	Gnaisse	CP III RS 40	28	2,53	3,13	0,60	3	32,85	B
1008	Gnaisse	CP IV 32	28	1,40	2,10	0,60	0	15	B
1009	Gnaisse	CP IV 32	28	1,40	2,10	0,60	0	18	B
1010	Gnaisse	CP IV 32	28	1,40	2,10	0,60	0	26	B
1011	Gnaisse	CP IV 32	28	1,40	2,10	0,60	0	23	B
1012	Gnaisse	CP IV 32	28	1,40	2,10	0,60	0	26	B
1013	Gnaisse	CP IV 32	28	1,40	2,10	0,60	0	38	B
1014	Gnaisse	CP V ARI	3	2,27	3,12	0,60	0,42	26,1	B
1015	Gnaisse	CP V ARI	28	2,27	3,12	0,60	0,42	30,7	B
1016	Gnaisse	CP V ARI	28	1,40	2,10	0,60	0	28	B
1017	Gnaisse	CP V ARI	28	1,40	2,10	0,60	0	39	B
1018	Gnaisse	CP V ARI	28	1,40	2,10	0,60	0	45	B
1019	Gnaisse	CP V ARI	14	2,27	3,12	0,60	0,42	33,2	B
1020	Gnaisse	CP V ARI	28	2,27	3,12	0,60	0,42	34,2	B
1021	Gnaisse	CP V ARI	28	1,40	2,10	0,60	0	33	B
1022	Gnaisse	CP V ARI	28	1,40	2,10	0,60	0	42	B
1023	Gnaisse	CP V ARI	28	1,40	2,10	0,60	0	48	B
1024	Gnaisse	CP V ARI	56	2,27	3,12	0,60	0,42	37,9	B
1025	Gnaisse	CP II F 32	28	1,95	3,82	0,60	0	25	B
1026	Gnaisse	CP II F 32	28	1,95	3,82	0,60	0	34	B
1027	Gnaisse	CP II F 32	28	1,95	3,82	0,60	0	39	B
1028	Gnaisse	CP II F 32	28	1,95	3,82	0,60	0	29	B
1029	Gnaisse	CP II F 32	28	1,95	3,82	0,60	0	38	B
1030	Gnaisse	CP II F 32	28	1,95	3,82	0,60	0	47	B
1031	Seixo rolado	CP II E 32	28	2,57	3,34	0,60	0	21	B

1032	Seixo rolado	CP II E 32	28	2,57	3,34	0,60	0	33	B
1033	Seixo rolado	CP II F 32	28	2,57	3,34	0,60	0	25	B
1034	Seixo rolado	CP II F 32	28	2,57	3,34	0,60	0	31	B
1035	Seixo rolado	CP II Z 32	28	2,57	3,34	0,60	0	20	B
1036	Seixo rolado	CP II Z 32	28	2,57	3,34	0,60	0	35	B
1037	Sienito	CP III RS 40	3	2,72	3,58	0,60	3	18,8	B
1038	Sienito	CP III RS 40	3	2,62	3,49	0,60	3	20,68	B
1039	Sienito	CP III RS 40	3	2,71	3,58	0,60	3	16,92	B
1040	Sienito	CP III RS 40	7	2,72	3,58	0,60	3	28,3	B
1041	Sienito	CP III RS 40	7	2,62	3,49	0,60	3	31,13	B
1042	Sienito	CP III RS 40	7	2,71	3,58	0,60	3	25,47	B
1043	Sienito	CP III RS 40	14	2,72	3,58	0,60	3	33,5	B
1044	Sienito	CP III RS 40	14	2,62	3,49	0,60	3	36,85	B
1045	Sienito	CP III RS 40	14	2,71	3,58	0,60	3	30,15	B
1046	Sienito	CP III RS 40	28	2,72	3,58	0,60	3	40,2	B
1047	Sienito	CP III RS 40	28	2,62	3,49	0,60	3	44,22	B
1048	Sienito	CP III RS 40	28	2,71	3,58	0,60	3	36,18	B
1049	Traquito	CP III 32	3	2,27	3,12	0,60	0,42	9,5	B
1050	Traquito	CP III 32	28	2,27	3,12	0,60	0,42	22,4	B
1051	Traquito	CP III 32	14	2,27	3,12	0,60	0,42	34,6	B
1052	Traquito	CP III 32	28	2,27	3,12	0,60	0,42	28,7	B
1053	Traquito	CP III 32	56	2,27	3,12	0,60	0,42	31,3	B
1054	Basalto	CP IV 32	28	3,40	3,60	0,61	0	29	B
1055	Basalto	CP IV 32	28	3,40	3,60	0,61	0	30,7	B
1056	Basalto	CP IV 32	28	3,40	3,60	0,61	0	29,9	B
1057	Basalto	CP IV 32	28	3,40	3,60	0,61	0	30,9	B
1058	Basalto	CP V ARI	3	2,50	3,51	0,61	0	29,01	B
1059	Basalto	CP V ARI	3	2,50	3,51	0,61	0	28,61	B
1060	Basalto	CP V ARI	3	2,50	3,51	0,61	0	29	B
1061	Basalto	CP V ARI	7	2,50	3,51	0,61	0	35,3	B
1062	Basalto	CP V ARI	7	2,50	3,51	0,61	0	35,1	B
1063	Basalto	CP V ARI	7	2,50	3,51	0,61	0	35,1	B
1064	Basalto	CP V ARI	28	2,50	3,51	0,61	0	39,8	B
1065	Basalto	CP V ARI	28	2,50	3,51	0,61	0	39,4	B
1066	Basalto	CP V ARI	28	2,50	3,51	0,61	0	38,8	B
1067	Basalto	CP II F 32	3	2,50	3,51	0,61	0	14,6	B
1068	Basalto	CP II F 32	3	2,50	3,51	0,61	0	15,2	B
1069	Basalto	CP II F 32	3	2,50	3,51	0,61	0	15,1	B
1070	Basalto	CP II F 32	7	2,50	3,51	0,61	0	21,2	B
1071	Basalto	CP II F 32	7	2,50	3,51	0,61	0	22,5	B
1072	Basalto	CP II F 32	7	2,50	3,51	0,61	0	21,6	B
1073	Basalto	CP II F 32	28	2,50	3,51	0,61	0	31,6	B
1074	Basalto	CP II F 32	28	2,50	3,51	0,61	0	30	B
1075	Basalto	CP II F 32	28	2,50	3,51	0,61	0	30,4	B
1076	Basalto	CP II F 40	3	3,40	3,60	0,61	0,71	19,2	B
1077	Basalto	CP II F 40	7	3,40	3,60	0,61	0,71	36,4	B
1078	Basalto	CP II F 40	28	3,40	3,60	0,61	0,71	38,3	B

1079	Calcario	CP III RS 40	3	1,84	3,99	0,61	0,6	5,2	B
1080	Calcario	CP III RS 40	3	1,84	3,99	0,61	0,6	5,16	B
1081	Calcario	CP III RS 40	3	1,84	3,99	0,61	0,6	5	B
1082	Calcario	CP III RS 40	3	1,77	3,45	0,61	0,6	5,33	B
1083	Calcario	CP III RS 40	3	1,77	3,45	0,61	0,6	5,29	B
1084	Calcario	CP III RS 40	3	1,77	3,45	0,61	0,6	5,13	B
1085	Calcario	CP III RS 40	7	1,84	3,99	0,61	0,6	14,57	B
1086	Calcario	CP III RS 40	7	1,84	3,99	0,61	0,6	14,47	B
1087	Calcario	CP III RS 40	7	1,84	3,99	0,61	0,6	14,01	B
1088	Calcario	CP III RS 40	7	1,77	3,45	0,61	0,6	14,96	B
1089	Calcario	CP III RS 40	7	1,77	3,45	0,61	0,6	14,84	B
1090	Calcario	CP III RS 40	7	1,77	3,45	0,61	0,6	14,38	B
1091	Calcario	CP III RS 40	28	1,84	3,99	0,61	0,6	26,11	B
1092	Calcario	CP III RS 40	28	1,84	3,99	0,61	0,6	25,92	B
1093	Calcario	CP III RS 40	28	1,84	3,99	0,61	0,6	25,11	B
1094	Calcario	CP III RS 40	28	1,84	3,99	0,61	0,6	25,68	B
1095	Calcario	CP III RS 40	28	1,84	3,99	0,61	0,6	25,3	B
1096	Calcario	CP III RS 40	28	1,77	3,45	0,61	0,6	26,8	B
1097	Calcario	CP III RS 40	28	1,77	3,45	0,61	0,6	26,6	B
1098	Calcario	CP III RS 40	28	1,77	3,45	0,61	0,6	25,77	B
1099	Calcario	CP III RS 40	28	1,77	3,45	0,61	0,6	26,35	B
1100	Calcario	CP III RS 40	28	1,77	3,45	0,61	0,6	25,97	B
1101	Calcario	CP IV 32	7	3,40	3,60	0,61	0	21,71	B
1102	Calcario	CP IV 32	7	3,40	3,60	0,61	0	21,39	B
1103	Calcario	CP IV 32	7	3,40	3,60	0,61	0	20,96	B
1104	Calcario	CP IV 32	7	3,12	3,11	0,61	0	20,79	B
1105	Calcario	CP IV 32	28	3,40	3,60	0,61	0	26,03	B
1106	Calcario	CP IV 32	28	3,40	3,60	0,61	0	26,09	B
1107	Calcario	CP IV 32	28	3,40	3,60	0,61	0	26,64	B
1108	Calcario	CP IV 32	28	3,12	3,11	0,61	0	28,97	B
1109	Calcario	CP IV 32	28	3,40	3,60	0,61	0	26,7	B
1110	Calcario	CP IV 32	28	3,40	3,60	0,61	0	28,3	B
1111	Calcario	CP IV 32	28	3,40	3,60	0,61	0	27,9	B
1112	Calcario	CP IV 32	28	3,12	3,11	0,61	0	27,8	B
1113	Diabasio	CP IV 32	28	3,40	3,60	0,61	0	26,2	B
1114	Diabasio	CP IV 32	28	3,40	3,60	0,61	0	25	B
1115	Diabasio	CP IV 32	28	3,40	3,60	0,61	0	25,1	B
1116	Diabasio	CP IV 32	28	3,40	3,60	0,61	0	25,4	B
1117	Gnaïsse	CP IV 32	28	3,40	3,60	0,61	0	18,5	B
1118	Gnaïsse	CP IV 32	28	3,40	3,60	0,61	0	17,9	B
1119	Gnaïsse	CP IV 32	28	3,40	3,60	0,61	0	16,1	B
1120	Gnaïsse	CP IV 32	28	3,40	3,60	0,61	0	16,9	B
1121	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	21,49	B
1122	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,23	B
1123	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,52	B
1124	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,13	B
1125	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,85	B

1126	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,69	B
1127	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,66	B
1128	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	21,96	B
1129	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,71	B
1130	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	26,7	B
1131	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	28,3	B
1132	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	27,9	B
1133	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	27,8	B
1134	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	25,86	B
1135	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	27,57	B
1136	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	28,81	B
1137	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	25,74	B
1138	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	26,76	B
1139	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	25,68	B
1140	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	26,43	B
1141	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	27,94	B
1142	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	24,06	B
1143	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	25,93	B
1144	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	21,71	B
1145	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	21,39	B
1146	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,96	B
1147	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,79	B
1148	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	21,49	B
1149	Granito	CP III RS 40	7	3,60	3,40	0,61	0,49	20,23	B
1150	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,52	B
1151	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,13	B
1152	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,85	B
1153	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,69	B
1154	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,66	B
1155	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	21,96	B
1156	Granito	CP III RS 40	7	2,50	3,51	0,61	0,49	20,71	B
1157	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	25,86	B
1158	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	26,03	B
1159	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	26,09	B
1160	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	26,64	B
1161	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	28,97	B
1162	Granito	CP III RS 40	28	3,60	3,40	0,61	0,49	27,57	B
1163	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	28,81	C
1164	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	25,74	C
1165	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	26,76	C
1166	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	25,68	C
1167	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	26,43	C
1168	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	27,94	C
1169	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	24,06	C
1170	Granito	CP III RS 40	28	2,50	3,51	0,61	0,49	25,93	C
1171	Granito	CP III RS 40	56	3,60	3,40	0,61	0,49	29,68	A
1172	Granito	CP III RS 40	56	3,60	3,40	0,61	0,49	33,27	A
1173	Granito	CP III RS 40	56	3,60	3,40	0,61	0,49	29,99	A

1174	Granito	CP III RS 40	56	3,60	3,40	0,61	0,49	28,06	A
1175	Granito	CP III RS 40	56	3,60	3,40	0,61	0,49	31,04	A
1176	Granito	CP III RS 40	56	3,60	3,40	0,61	0,49	30,26	A
1177	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	30,33	A
1178	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	31,81	A
1179	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	30,66	A
1180	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	32,43	A
1181	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	34,18	A
1182	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	36,01	A
1183	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	32,64	A
1184	Granito	CP III RS 40	56	2,50	3,51	0,61	0,49	33,26	A
1185	Granito	CP IV 32	28	3,40	3,60	0,61	0	26,8	C
1186	Granito	CP IV 32	28	3,40	3,60	0,61	0	27,3	C
1187	Granito	CP IV 32	28	3,40	3,60	0,61	0	27,3	C
1188	Granito	CP IV 32	28	3,40	3,60	0,61	0	27,8	C
1189	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	17,98	B
1190	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,17	B
1191	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	19,07	B
1192	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	17,91	B
1193	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,3	B
1194	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,44	B
1195	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,66	B
1196	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,19	B
1197	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	17,03	B
1198	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,49	B
1199	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	17,85	B
1200	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,08	B
1201	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	18,49	B
1202	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	19,22	B
1203	Granito	CP III RS 40	7	3,23	3,77	0,62	0,72	17,18	B
1204	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	26,33	C
1205	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	25,75	C
1206	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	25,24	C
1207	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,63	C
1208	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,12	C
1209	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	25,93	C
1210	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	27,03	C
1211	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,8	C
1212	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,93	C
1213	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	27,46	C
1214	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,8	C
1215	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,93	C
1216	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	27,46	C
1217	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	26,72	C
1218	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,95	C
1219	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	25,49	C
1220	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	26,53	C

1221	Granito	CP III RS 40	28	3,23	3,77	0,62	0,72	24,76	C
1222	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	36,4	A
1223	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	36,66	A
1224	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	37,18	A
1225	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	36,05	A
1226	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	37,49	A
1227	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	34,81	A
1228	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	29,4	A
1229	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	33,8	A
1230	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	38,98	A
1231	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	38,17	A
1232	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	37,92	A
1233	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	29,8	A
1234	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	37,34	A
1235	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	34,92	A
1236	Granito	CP III RS 40	56	3,23	3,77	0,62	0,72	40,16	A
1237	Granulito	CP II F 32	7	2,83	3,40	0,63	0,6	23,45	B
1238	Granulito	CP II F 32	7	2,83	3,40	0,63	0,6	21,92	B
1239	Granulito	CP II F 32	7	2,83	3,40	0,63	0,6	30,05	B
1240	Granulito	CP II F 32	28	2,83	3,40	0,63	0,6	32,15	C
1241	Granulito	CP II F 32	28	2,83	3,40	0,63	0,6	30,15	C
1242	Granulito	CP II F 32	28	2,83	3,40	0,63	0,6	30,05	C
1243	Granito	CP II E 32	28	1,15	2,85	0,64	0	24,74	C
1244	Granito	CP II E 32	28	1,15	2,85	0,64	0	24	C
1245	Granito	CP II E 32	28	2,01	3,99	0,64	0	24	C
1246	Basalto	CP II F 40	3	2,00	2,50	0,65	1,44	13,4	B
1247	Basalto	CP II F 40	7	2,00	2,50	0,65	1,44	18,8	B
1248	Basalto	CP II F 40	28	2,00	2,50	0,65	1,44	28,3	C
1249	Calcario	CP V ARI	28	2,00	2,50	0,65	0	23	C
1250	Calcario	CP V ARI	28	2,00	2,50	0,65	0	24	C
1251	Calcario	CP V ARI	28	2,00	2,50	0,65	0	25	C
1252	Gnaisse	CP III 32	3	3,23	3,32	0,65	0,45	10,8	B
1253	Gnaisse	CP III 32	7	3,23	3,32	0,65	0,45	18	B
1254	Gnaisse	CP III 32	14	3,23	3,32	0,65	0,45	20,2	B
1255	Gnaisse	CP III 32	28	3,23	3,32	0,65	0,45	21	C
1256	Gnaisse	CP III 32	56	3,23	3,32	0,65	0,45	27,4	A
1257	Gnaisse	CP V ARI	3	2,00	2,50	0,65	0,43	23,3	B
1258	Gnaisse	CP V ARI	7	2,00	2,50	0,65	0,43	24,2	B
1259	Gnaisse	CP V ARI	14	2,00	2,50	0,65	0,43	25,6	B
1260	Gnaisse	CP V ARI	28	2,00	2,50	0,65	0,43	26,5	C
1261	Gnaisse	CP V ARI	56	2,00	2,50	0,65	0,43	31,4	A
1262	Gnaisse	CP V ARI	28	2,00	2,50	0,65	0	29	C
1263	Gnaisse	CP V ARI	28	2,00	2,50	0,65	0	30	C
1264	Gnaisse	CP V ARI	28	2,00	2,50	0,65	0	31	C
1265	Micaxisto	CP II F 32	7	2,97	3,52	0,65	0,6	22,66	B
1266	Micaxisto	CP II F 32	7	2,97	3,52	0,65	0,6	22,31	B
1267	Micaxisto	CP II F 32	7	2,97	3,52	0,65	0,6	23,71	B

1268	Micaxisto	CP II F 32	28	2,97	3,52	0,65	0,6	23,16	C
1269	Micaxisto	CP II F 32	28	2,97	3,52	0,65	0,6	22,83	C
1270	Micaxisto	CP II F 32	28	2,97	3,52	0,65	0,6	23,68	C
1271	Quartzo	CP V ARI	28	3,02	3,88	0,65	0	30	C
1272	Quartzo	CP V ARI	28	2,91	3,88	0,65	0	31	C
1273	Quartzo	CP V ARI	28	3,02	3,88	0,65	0	32	C
1274	Traquito	CP III 32	3	2,00	2,50	0,65	0,43	8	B
1275	Traquito	CP III 32	7	2,00	2,50	0,65	0,43	18,4	B
1276	Traquito	CP III 32	14	2,00	2,50	0,65	0,43	19,7	B
1277	Traquito	CP III 32	28	2,00	2,50	0,65	0,43	26,6	C
1278	Traquito	CP III 32	56	2,00	2,50	0,65	0,43	27,7	A
1279	Basalto	CP II F 40	3	3,38	3,12	0,67	0,74	13,1	B
1280	Basalto	CP II F 40	7	3,38	3,12	0,67	0,74	18,2	B
1281	Basalto	CP II F 40	28	3,38	3,12	0,67	0,74	26,9	C
1282	Gnaisse	CP III 32	28	3,46	3,44	0,67	0	25	C
1283	Calcario	CP III RS 40	3	2,11	4,44	0,68	0,6	4,4	B
1284	Calcario	CP III RS 40	3	2,11	4,44	0,68	0,6	4,37	B
1285	Calcario	CP III RS 40	3	2,11	4,44	0,68	0,6	4,23	B
1286	Calcario	CP III RS 40	3	2,06	3,85	0,68	0,6	4,37	B
1287	Calcario	CP III RS 40	3	2,06	3,85	0,68	0,6	4,34	B
1288	Calcario	CP III RS 40	3	2,06	3,85	0,68	0,6	4,2	B
1289	Calcario	CP III RS 40	7	2,11	4,44	0,68	0,6	12,35	B
1290	Calcario	CP III RS 40	7	2,11	4,44	0,68	0,6	12,26	B
1291	Calcario	CP III RS 40	7	2,11	4,44	0,68	0,6	11,87	B
1292	Calcario	CP III RS 40	7	2,06	3,85	0,68	0,6	12,26	B
1293	Calcario	CP III RS 40	7	2,06	3,85	0,68	0,6	12,16	B
1294	Calcario	CP III RS 40	7	2,06	3,85	0,68	0,6	11,79	B
1295	Calcario	CP III RS 40	28	2,11	4,44	0,68	0,6	22,13	C
1296	Calcario	CP III RS 40	28	2,11	4,44	0,68	0,6	21,97	C
1297	Calcario	CP III RS 40	28	2,11	4,44	0,68	0,6	21,28	C
1298	Calcario	CP III RS 40	28	2,11	4,44	0,68	0,6	21,76	C
1299	Calcario	CP III RS 40	28	2,11	4,44	0,68	0,6	21,44	C
1300	Calcario	CP III RS 40	28	2,06	3,85	0,68	0,6	21,97	C
1301	Calcario	CP III RS 40	28	2,06	3,85	0,68	0,6	21,8	C
1302	Calcario	CP III RS 40	28	2,06	3,85	0,68	0,6	21,12	C
1303	Calcario	CP III RS 40	28	2,06	3,85	0,68	0,6	21,6	C
1304	Calcario	CP III RS 40	28	2,06	3,85	0,68	0,6	21,29	C
1305	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	23,96	C
1306	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	23,49	C
1307	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	24,94	C
1308	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	24,53	C
1309	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	23,89	C
1310	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	24,3	C
1311	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	23,76	C
1312	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	26,36	C
1313	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	24,74	C
1314	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	24,22	C

1315	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	28,18	C
1316	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	26,88	C
1317	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	23,65	C
1318	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	24,32	C
1319	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	23,41	C
1320	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	28,77	C
1321	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,22	C
1322	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,78	C
1323	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,05	C
1324	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,16	C
1325	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	27,73	C
1326	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	27,87	C
1327	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	28,66	C
1328	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,86	C
1329	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	27,55	C
1330	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	31,49	C
1331	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	27,41	C
1332	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,79	C
1333	Granito	CP III RS 40	28	3,29	4,86	0,69	0,5	29,5	C
1334	Basalto	CP IV 32	7	2,14	3,77	0,70	0	14	B
1335	Basalto	CP IV 32	7	2,14	3,77	0,70	0	14	B
1336	Basalto	CP IV 32	14	2,14	3,77	0,70	0	18	B
1337	Basalto	CP IV 32	28	2,14	3,77	0,70	0	19	B
1338	Basalto	CP V ARI	7	2,23	3,77	0,70	0	25	B
1339	Basalto	CP V ARI	7	2,23	3,77	0,70	0	25	B
1340	Basalto	CP V ARI	14	2,23	3,77	0,70	0	27	B
1341	Basalto	CP V ARI	28	2,23	3,77	0,70	0	27	C
1342	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	12,38	B
1343	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	10,91	B
1344	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	10,50	B
1345	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	10,51	B
1346	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	12,38	B
1347	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	10,91	B
1348	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	10,50	B
1349	Gnaïsse	CP II Z 32	7	2,20	2,90	0,70	0	10,51	B
1350	Gnaïsse	CP II Z 32	14	2,20	2,90	0,70	0	13,14	B
1351	Gnaïsse	CP II Z 32	14	2,20	2,90	0,70	0	13,70	B
1352	Gnaïsse	CP II Z 32	14	2,20	2,90	0,70	0	13,51	B
1353	Gnaïsse	CP II Z 32	14	2,20	2,90	0,70	0	13,34	B
1354	Gnaïsse	CP II Z 32	28	2,20	2,90	0,70	0	14,75	C
1355	Gnaïsse	CP II Z 32	28	2,20	2,90	0,70	0	14,45	C
1356	Gnaïsse	CP II Z 32	28	2,20	2,90	0,70	0	14,07	C
1357	Gnaïsse	CP II Z 32	28	2,20	2,90	0,70	0	13,15	C
1358	Gnaïsse	CP II Z 32	56,00	2,20	2,90	0,70	0	14,77	A
1359	Gnaïsse	CP II Z 32	56,00	2,20	2,90	0,70	0	14,66	A
1360	Gnaïsse	CP II Z 32	56,00	2,20	2,90	0,70	0	14,18	A
1361	Calcario	CP III RS 40	3	2,25	4,66	0,71	0,6	3,73	B

1362	Calcario	CP III RS 40	3	2,25	4,66	0,71	0,6	3,71	B
1363	Calcario	CP III RS 40	3	2,25	4,66	0,71	0,6	3,59	B
1364	Calcario	CP III RS 40	3	2,18	4,02	0,71	0,6	3,94	B
1365	Calcario	CP III RS 40	3	2,18	4,02	0,71	0,6	3,91	B
1366	Calcario	CP III RS 40	3	2,18	4,02	0,71	0,6	3,79	B
1367	Calcario	CP III RS 40	7	2,25	4,66	0,71	0,6	10,46	B
1368	Calcario	CP III RS 40	7	2,25	4,66	0,71	0,6	10,39	B
1369	Calcario	CP III RS 40	7	2,25	4,66	0,71	0,6	10,06	B
1370	Calcario	CP III RS 40	7	2,18	4,02	0,71	0,6	11,04	B
1371	Calcario	CP III RS 40	7	2,18	4,02	0,71	0,6	10,96	B
1372	Calcario	CP III RS 40	7	2,18	4,02	0,71	0,6	10,62	B
1373	Calcario	CP III RS 40	28	2,25	4,66	0,71	0,6	18,75	C
1374	Calcario	CP III RS 40	28	2,25	4,66	0,71	0,6	18,62	C
1375	Calcario	CP III RS 40	28	2,25	4,66	0,71	0,6	18,03	C
1376	Calcario	CP III RS 40	28	2,25	4,66	0,71	0,6	18,44	C
1377	Calcario	CP III RS 40	28	2,25	4,66	0,71	0,6	18,17	C
1378	Calcario	CP III RS 40	28	2,18	4,02	0,71	0,6	19,79	C
1379	Calcario	CP III RS 40	28	2,18	4,02	0,71	0,6	19,64	C
1380	Calcario	CP III RS 40	28	2,18	4,02	0,71	0,6	19,03	C
1381	Calcario	CP III RS 40	28	2,18	4,02	0,71	0,6	19,46	C
1382	Calcario	CP III RS 40	28	2,18	4,02	0,71	0,6	19,18	C
1383	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	34,8	C
1384	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	31,7	C
1385	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	32,9	C
1386	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	31,9	C
1387	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	33	C
1388	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	38,9	C
1389	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35	C
1390	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	34	C
1391	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	33	C
1392	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	32,9	C
1393	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	38,6	C
1394	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	38,7	C
1395	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	37,8	C
1396	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,1	C
1397	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	38,7	C
1398	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	25,9	C
1399	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	38,5	C
1400	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,9	C
1401	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	38,4	C
1402	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	37,3	C
1403	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,4	C
1404	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,9	C
1405	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,9	C
1406	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,4	C
1407	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	37,7	C
1408	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,9	C

1409	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	31,7	C
1410	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	37	C
1411	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	37,8	C
1412	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,5	C
1413	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,2	C
1414	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,8	C
1415	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,5	C
1416	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,1	C
1417	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,9	C
1418	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,6	C
1419	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35,2	C
1420	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36,3	C
1421	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	36	C
1422	Granito	CP V ARI	28	3,78	4,23	0,73	1,1	35	C
1423	Basalto	CP II F 32	7	4,01	4,45	0,74	0,6	15,24	C
1424	Basalto	CP II F 32	7	4,01	4,45	0,74	0,6	15,88	B
1425	Basalto	CP II F 32	7	4,01	4,45	0,74	0,6	17,86	B
1426	Basalto	CP II F 32	28	4,01	4,45	0,74	0,6	22,96	C
1427	Basalto	CP II F 32	28	4,01	4,45	0,74	0,6	22,98	C
1428	Basalto	CP II F 32	28	4,01	4,45	0,74	0,6	21,16	C
1429	Granito	CP II E 32	28	1,15	2,85	0,74	0	20,32	C
1430	Esteril	CP II Z 32	7	2,12	2,73	0,50	0	19,78	A, B e C
1431	Esteril	CP II Z 32	7	2,12	2,73	0,50	0	20,00	A, B e C
1432	Esteril	CP II Z 32	7	2,13	2,77	0,50	0	19,20	A, B e C
1433	Esteril	CP II Z 32	7	2,13	2,77	0,50	0	20,84	A, B e C
1434	Esteril	CP II Z 32	7	2,13	2,77	0,50	0	21,33	A, B e C
1435	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	19,62	A, B e C
1436	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	21,95	A, B e C
1437	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	20,08	A, B e C
1438	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	21,71	A, B e C
1439	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	20,84	A, B e C
1440	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	19,40	A, B e C
1441	Esteril	CP II Z 32	7	1,40	2,10	0,50	0	18,74	A, B e C
1442	Esteril	CP II Z 32	14	2,12	2,73	0,50	0	18,75	A, B e C
1443	Esteril	CP II Z 32	14	2,12	2,73	0,50	0	20,58	A, B e C
1444	Esteril	CP II Z 32	14	2,13	2,77	0,50	0	22,80	A, B e C
1445	Esteril	CP II Z 32	14	2,13	2,77	0,50	0	23,37	A, B e C
1446	Esteril	CP II Z 32	14	2,13	2,77	0,50	0	23,14	A, B e C
1447	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	20,95	A, B e C
1448	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	24,57	A, B e C
1449	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	21,08	A, B e C
1450	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	22,09	A, B e C
1451	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	20,61	A, B e C
1452	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	24,40	A, B e C
1453	Esteril	CP II Z 32	14	1,40	2,10	0,50	0	22,49	A, B e C
1454	Esteril	CP II Z 32	28	2,12	2,73	0,50	0	25,95	A, B e C
1455	Esteril	CP II Z 32	28	2,12	2,73	0,50	0	24,61	A, B e C
1456	Esteril	CP II Z 32	28	2,13	2,77	0,50	0	27,77	A, B e C
1457	Esteril	CP II Z 32	28	2,13	2,77	0,50	0	24,87	A, B e C
1458	Esteril	CP II Z 32	28	2,13	2,77	0,50	0	27,13	A, B e C

1459	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	25,71	A, B e C
1460	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	24,09	A, B e C
1461	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	27,15	A, B e C
1462	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	24,75	A, B e C
1463	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	26,45	A, B e C
1464	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	23,36	A, B e C
1465	Esteril	CP II Z 32	28	1,40	2,10	0,50	0	27,00	A, B e C
1466	Esteril	CP II Z 32	56	2,12	2,73	0,50	0	23,69	A, B e C
1467	Esteril	CP II Z 32	56	2,12	2,73	0,50	0	24,82	A, B e C
1468	Esteril	CP II Z 32	56	2,13	2,77	0,50	0	25,91	A, B e C
1469	Esteril	CP II Z 32	56	2,13	2,77	0,50	0	26,45	A, B e C
1470	Esteril	CP II Z 32	56	2,13	2,77	0,50	0	25,97	A, B e C
1471	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	28,23	A, B e C
1472	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	25,12	A, B e C
1473	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	24,71	A, B e C
1474	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	24,95	A, B e C
1475	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	26,02	A, B e C
1476	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	26,80	A, B e C
1477	Esteril	CP II Z 32	56	1,40	2,10	0,50	0	24,64	A, B e C
1478	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	12,27	A, B e C
1479	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	12,54	A, B e C
1480	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	11,87	A, B e C
1481	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	12,65	A, B e C
1482	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	14,10	A, B e C
1483	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	13,97	A, B e C
1484	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	14,26	A, B e C
1485	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	14,71	A, B e C
1486	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	12,27	A, B e C
1487	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	12,54	A, B e C
1488	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	11,87	A, B e C
1489	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	12,65	A, B e C
1490	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	14,10	A, B e C
1491	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	13,97	A, B e C
1492	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	14,26	A, B e C
1493	Esteril	CP II Z 32	7	2,20	2,90	0,70	0	14,71	A, B e C
1494	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	14,71	A, B e C
1495	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	14,53	A, B e C
1496	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	15,31	A, B e C
1497	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	13,47	A, B e C
1498	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	15,17	A, B e C
1499	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	15,24	A, B e C
1500	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	14,02	A, B e C
1501	Esteril	CP II Z 32	14	2,20	2,90	0,70	0	16,40	A, B e C
1502	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	16,56	A, B e C
1503	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	15,26	A, B e C
1504	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	16,77	A, B e C
1505	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	15,50	A, B e C
1506	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	16,61	A, B e C
1507	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	16,56	A, B e C
1508	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	15,06	A, B e C
1509	Esteril	CP II Z 32	28	2,20	2,90	0,70	0	16,21	A, B e C
1510	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	15,96	A, B e C

<b>1511</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	16,73	A, B e C
<b>1512</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	15,65	A, B e C
<b>1513</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	16,38	A, B e C
<b>1514</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	15,41	A, B e C
<b>1515</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	16,83	A, B e C
<b>1516</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	17,47	A, B e C
<b>1517</b>	Esteril	CP II Z 32	56	2,20	2,90	0,70	0	17,39	A, B e C