

**UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE ENGENHARIAS, CIÊNCIAS AGRÁRIAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA**

ROGÉRIO KRAFT KÖHLER

**CLASSIFICAÇÃO DE AGREGADOS DE ROCHAS ÍGNEAS QUANTO À SUA
ALTERAÇÃO POR MEIO DE PROCESSAMENTO DIGITAL DE IMAGENS**

**PONTA GROSSA
2021**

ROGÉRIO KRAFT KÖHLER

**CLASSIFICAÇÃO DE AGREGADOS DE ROCHAS ÍGNEAS QUANTO À SUA
ALTERAÇÃO POR MEIO DE PROCESSAMENTO DIGITAL DE IMAGENS**

Dissertação submetida ao Programa de Pós Graduação em Computação Aplicada para obtenção do título de Mestre na Universidade Estadual de Ponta Grossa, Área de concentração: Computação para Tecnologias Agrícolas.

Orientador: Prof. Dr. Luciano José Senger
Coorientadora: Profa. Dra. Lilian Tais de Gouveia

**PONTA GROSSA
2021**

K79 Köhler, Rogério Kraft
Classificação de agregados de rochas ígneas quanto à sua alteração por meio de processamento digital de imagens / Rogério Kraft Köhler. Ponta Grossa, 2021.
145 f.

Dissertação (Mestrado em Computação Aplicada - Área de Concentração: Computação para Tecnologias em Agricultura), Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Luciano José Senger.
Coorientadora: Profa. Dra. Lilian Tais de Gouveia.

1. Classificação. 2. Análise de textura. 3. Mineração de dados. 4. Agregados minerais. I. Senger, Luciano José. II. Gouveia, Lilian Tais de. III. Universidade Estadual de Ponta Grossa. Computação para Tecnologias em Agricultura. IV.T.

CDD: 004



UNIVERSIDADE ESTADUAL DE PONTA GROSSA
Av. General Carlos Cavalcanti, 4748 - Bairro Uvaranas - CEP 84030-900 - Ponta Grossa - PR - <https://uepg.br>

TERMO

TERMO DE APROVAÇÃO

Rogério Kraft Köhler

CLASSIFICAÇÃO DE AGREGADOS DE ROCHAS ÍGNEAS QUANTO À SUA ALTERAÇÃO POR MEIO DE PROCESSAMENTO DIGITAL DE IMAGENS

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Prof. Dr. Luciano José Senger

Prof. Dr. Arion de Campos Júnior

Prof. Dr. Renato Porfírio Ishii

Ponta Grossa, 06 de agosto de 2021



Documento assinado eletronicamente por **Luciano Jose Senger, Professor(a)**, em 06/08/2021, às 13:59, conforme Resolução UEPG CA 114/2018 e art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **Arion de Campos Junior, Professor(a)**, em 06/08/2021, às 14:00, conforme Resolução UEPG CA 114/2018 e art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **Renato Porfírio Ishii, Usuário Externo**, em 11/08/2021, às 16:30, conforme Resolução UEPG CA 114/2018 e art. 1º, III, "b", da Lei 11.419/2006.

A autenticidade do documento pode ser conferida no site <https://sei.uepg.br/autenticidade> informando o código verificador **0574977** e o código CRC **717871CF**.



21.000027760-6

0574977v4

AGRADECIMENTOS

A Universidade Estadual de Ponta Grossa, por fornecer ensino de qualidade.

Ao programa de Pós graduação em Computação Aplicada, por fornecer excelentes laboratórios e estrutura para o desenvolvimento da pesquisa.

Aos meus orientadores, Profa. Dra. Lilian Tais de Gouveia e Prof. Dr. Luciano José Senger que me guiaram e orientaram com profissionalismo e dedicação impar, doando precioso tempo no decorrer da pesquisa e me auxiliando nas dificuldades enfrentadas.

Ao coordenador do curso, Prof. Dr. José Carlos Ferreira da Rocha, que sempre me auxiliou em todas as minhas dúvidas e nas questões administrativas.

A Profa. Dra. Alaine Margarete Guimarães, que, de forma muito sensível, me aconselhou e me apoiou em um momento de incerteza sobre a permanência neste desafio.

Aos demais professores que ofereceram preciosos conhecimento durante o curso.

Aos meus pais, Maria Bernadete e Ari, meus grandes incentivadores da continuação dos meus estudos.

Aos meus irmãos, Maria Luiza e Ricardo, que ofereceram apoio sempre que necessitei.

A minha esposa Juliana e minha filha Eloísa, que abdicaram da minha presença e atenção, enquanto desenvolvia a pesquisa e pela atenção nas conversas relacionadas à pesquisa que pacientemente ouviram.

A todos os meus amigos que me auxiliaram de diversas formas durante essa jornada.

Ao Criador, pela vida e todas as coisas que nela tem acrescentado.

*"Se desejas partilhar o concerto das bênçãos divinas, ama e serve, sem cogitar de ser amado e sem a expectativa de ver-se servido."
(Emmanuel)*

RESUMO

A construção de estradas de qualidade depende da escolha de material que ofereça resistência, durabilidade e segurança, descritas em normas próprias da engenharia civil. O agregado mineral é, comumente, utilizado em larga escala nas obras de pavimentação e, naturalmente, pode sofrer alteração em sua estrutura física-química devido ao intemperismo. Tal alteração no agregado, quando usado em obras de pavimentação, pode reduzir a qualidade e durabilidade. O objetivo do presente estudo foi investigar o uso de Processamento digital de imagem na classificação de agregados de rochas ígneas levando em conta o grau de alteração, e assim destiná-las da forma mais correta para uso em construção de pavimentos asfálticos. O material investigado foi o basalto e o granito. O uso de ferramentas de análise de textura como a escala em tons de cinza, a frequência dos canais *Red*, *Green*, *Blue*, a Entropia, *Local binary patterns*, *Local binary patterns Uniform* e Matriz de co-ocorrência foram investigados. Os classificadores utilizados foram o *K-Nearest Neighbors*, *Multi-layer Perceptron*, *Árvore de decisão*, *Naive Bayes* e *Random forest*. Os resultados foram submetidos à análise estatísticas por meio de teste de Friedman e Nemenyi para verificar diferenças estatísticas. Concluiu-se que os descritores de textura são promissores para classificação quanto ao grau de alteração dos agregados, apresentando resultados de 100% de acerto, em alguns casos, para ambos os tipos de agregados. Os descritores de textura LBP, LBPU, GLCM apresentaram resultados promissores para experimentos com amostras de imagens sem ruído, enquanto as frequências dos canais RGB e a escala dos tons de cinza mostraram bom desempenho nos experimentos com imagens completas. Os algoritmos KNN e Random forest se mostraram eficazes na tarefa de classificação. Observou-se, ainda, resultados promissores quando granito e basalto são combinados e quando se utiliza amostras do agregado ou a imagem completa.

Palavras-chave: análise de textura, mineração de dados, agregados minerais, classificação.

ABSTRACT

The construction of quality roads/highways depends on the choice of material that offers strength, durability and safety, described in civil engineering standards. The mineral aggregate is commonly used in large scale on paving works and, naturally, it can suffer alterations in its physical-chemical structure due to weather conditions. Such alteration in the aggregate, when used in paving works may reduce quality and durability. The objective of the present study was to investigate the use of Digital Image Processing in the classification of igneous rock aggregates, taking into account the degree of alteration, and thus allocate them in the most appropriate way for use in asphalt sidewalk construction. The materials investigated were basalt and granite. The use of texture analysis tools such as grayscale, frequency of Red, Green, Blue channels, entropy, Local binary patterns, Local binary patterns Uniform and Co-occurrence matrix have been investigated. The classifiers used were K-Nearest Neighbors, Multi-layer Perceptron, Decision Tree, Naive Bayes and Random forest. The results were submitted to statistical analysis from the Friedman and Nemenyi test to verify statistical differences. It was concluded that the texture descriptors are promising regarding to classification as to the degree of alteration of the aggregates, presenting results of 100% accuracy, in some cases, for both types of aggregates. The texture descriptors LBP, LBPU, GLCM showed good results for the group A tests, while the RGB channel frequencies and grayscale showed good performance in the group B experiments. The KNN and Random forest algorithms proved to be effective in the classification task. Promising results were also observed when granite and basalt are combined and when using samples of the aggregate or the full image.

Keywords: texture analysis, data mining, mineral aggregates, classification.

LISTA DE FIGURAS

Figura 1 – Exemplos de agregado de granito alterado (A) e não alterado (B).	20
Figura 2 – Equipamento para ensaio de abrasão Los Angeles.	21
Figura 3 – Análise por peneiramento	22
Figura 4 – Estrutura do pavimento	23
Figura 5 – Exemplo de histograma	24
Figura 6 – Diferentes tipos de texturas	25
Figura 7 – Histograma de uma imagem de agregado	27
Figura 8 – Ângulos para cálculo da matriz de co-ocorrência	32
Figura 9 – Exemplo de vizinhança 3x3 - LBP	34
Figura 10 – Processo de limiarização - LBP	35
Figura 11 – Imagem com dois tons de cinza. Entropia = 1,00	36
Figura 12 – Imagem com diversos tons de cinza. Entropia = 6,26	36
Figura 13 – Fluxograma de classificação com treinamento e teste	38
Figura 14 – Exemplo de matriz de confusão	39
Figura 15 – Imagens de agregados e seus rótulos	42
Figura 16 – Imagens de agregados e seus rótulos	43
Figura 17 – Imagem original (esquerda) e imagem limiarizada (direita)	44
Figura 18 – Imagem original (I) e imagem recortada (II)	44
Figura 19 – Aplicação de Data Augmentation (DA))	45
Figura 20 – Gráfico das acurácias do basalto - KNN	52
Figura 21 – Gráfico das acurácias do basalto - NB	54
Figura 22 – Gráfico das acurácias do basalto - DT	55
Figura 23 – Gráfico das acurácias do basalto - MLP	56
Figura 24 – Gráfico das acurácias do basalto - RF	57
Figura 25 – Gráfico das acurácias do granito - KNN	59
Figura 26 – Gráfico das acurácias do granito - NB	60
Figura 27 – Gráfico das acurácias do granito - DT	62
Figura 28 – Gráfico das acurácias do granito - MLP	63
Figura 29 – Gráfico das acurácias do granito - RF	64
Figura 30 – Gráfico das acurácias do basalto + Granito - KNN	66
Figura 31 – Gráfico das acurácias do basalto + Granito - NB	67
Figura 32 – Gráfico das acurácias do basalto + Granito - DT	68
Figura 33 – Gráfico das acurácias do basalto + Granito - MLP	70
Figura 34 – Gráfico das acurácias do basalto + Granito - RF	71
Figura 35 – Gráfico das acurácias do basalto - KNN	72
Figura 36 – Gráfico das acurácias do basalto - NB	74
Figura 37 – Gráfico das acurácias do basalto - DT	75

Figura 38 – Gráfico das acurácias do basalto - MLP	76
Figura 39 – Gráfico das acurácias do basalto - RF	78
Figura 40 – Gráfico das acurácias do granito - KNN	79
Figura 41 – Gráfico das acurácias do granito - NB	80
Figura 42 – Gráfico das acurácias do granito - DT	81
Figura 43 – Gráfico das acurácias do granito - MLP	82
Figura 44 – Gráfico das acurácias do granito - RF	83
Figura 45 – Gráfico das acurácias do basalto + Granito - KNN	85
Figura 46 – Gráfico das acurácias do basalto + Granito - NB	86
Figura 47 – Gráfico das acurácias do basalto + Granito - DT	88
Figura 48 – Gráfico das acurácias do basalto + Granito - MLP	89
Figura 49 – Gráfico das acurácias do basalto + Granito - RF	91

LISTA DE TABELAS

Tabela 1 – Dimensões das aberturas das peneiras	22
Tabela 2 – Resumo de pesquisas	37
Tabela 3 – Características e rótulos do basalto	42
Tabela 4 – Características e rótulos granito	42
Tabela 5 – Grupos de imagens	45
Tabela 6 – Configuração final das bases	45
Tabela 7 – Descritores utilizados para classificação	49
Tabela 8 – Resultados de classificação KNN do basalto	53
Tabela 9 – Resultados de classificação Naive Bayes do basalto	54
Tabela 10 – Resultados de classificação árvore de decisão do basalto	55
Tabela 11 – Resultados de classificação MLP do basalto	57
Tabela 12 – Resultados de classificação <i>Random Forest</i> do basalto	58
Tabela 13 – Resultados de classificação KNN do granito	59
Tabela 14 – Resultados de classificação Naive Bayes do granito	61
Tabela 15 – Resultados de classificação Arvore de decisão do granito	62
Tabela 16 – Resultados de classificação MLP do granito	63
Tabela 17 – Resultados de classificação Random Forest do granito	65
Tabela 18 – Resultados de classificação KNN para basalto + Granito	66
Tabela 19 – Resultados de classificação NB para basalto + Granito	67
Tabela 20 – Resultados de classificação DT para basalto + Granito	69
Tabela 21 – Resultados de classificação MLP para basalto + Granito	70
Tabela 22 – Resultados de classificação RF para basalto + Granito	71
Tabela 23 – Resultados de classificação KNN para basalto	73
Tabela 24 – Resultados de classificação NB para basalto	74
Tabela 25 – Resultados de classificação DT para basalto	75
Tabela 26 – Resultados de classificação MLP para basalto	77
Tabela 27 – Resultados de classificação RF para basalto	78
Tabela 28 – Resultados de classificação KNN para granito	79
Tabela 29 – Resultados de classificação NB para granito	80
Tabela 30 – Resultados de classificação DT para granito	81
Tabela 31 – Resultados de classificação MLP para granito	82
Tabela 32 – Resultados de classificação RF para granito	84
Tabela 33 – Resultados de classificação KNN para basalto + Granito	85
Tabela 34 – Resultados de classificação NB para basalto + Granito	87
Tabela 35 – Resultados de classificação DT para basalto + Granito	88
Tabela 36 – Resultados de classificação MLP para basalto + Granito	90
Tabela 37 – Resultados de classificação RF para basalto + Granito	91

Tabela A1 – Resultado de Nemenyi - Basalto - KNN	107
Tabela A2 – Teste de Nemenyi - Basalto - NB	108
Tabela A3 – Teste de Nemenyi - Basalto - DT	109
Tabela A4 – Teste de Nemenyi - Basalto - MLP	110
Tabela A5 – Teste de Nemenyi - Basalto - RF	111
Tabela A6 – Resultado do teste de Nemenyi - Granito - KNN	112
Tabela A7 – Resultado do teste de Nemenyi - Granito - NB	113
Tabela A8 – Resultado do teste de Nemenyi - Granito - DT	114
Tabela A9 – Resultado do teste de Nemenyi - Granito - MLP	115
Tabela A10–Resultado do teste de Nemenyi - Granito - RF	116
Tabela A11–Resultado do teste Nemenyi - basalto + granito - KNN	117
Tabela A12–Resultado do teste Nemenyi - basalto + granito - NB	118
Tabela A13–Resultado do teste Nemenyi - basalto + granito - DT	119
Tabela A14–Resultado do teste Nemenyi - basalto + granito - MLP	120
Tabela A15–Resultado do teste Nemenyi - basalto + granito - RF	121
Tabela B16–Resultado de Nemenyi - Basalto - KNN	123
Tabela B17–Teste de Nemenyi - Basalto - NB	124
Tabela B18–Teste de Nemenyi - Basalto - DT	125
Tabela B19–Teste de Nemenyi - Basalto - MLP	126
Tabela B20–Teste de Nemenyi - Basalto - RF	127
Tabela B21–Resultado do teste de Nemenyi - Granito - KNN	128
Tabela B22–Resultado do teste de Nemenyi - Granito - NB	129
Tabela B23–Resultado do teste de Nemenyi - Granito - DT	130
Tabela B24–Resultado do teste de Nemenyi - Granito - MLP	131
Tabela B25–Resultado do teste de Nemenyi - Granito - RF	132
Tabela B26–Resultado do teste Nemenyi - basalto + granito - KNN	133
Tabela B27–Resultado do teste Nemenyi - basalto + granito - NB	134
Tabela B28–Resultado do teste Nemenyi - basalto + granito - DT	135
Tabela B29–Resultado do teste Nemenyi - basalto + granito - MLP	136
Tabela B30–Resultado do teste Nemenyi - basalto + granito - RF	137

LISTA DE CÓDIGOS

3.1	Código de alteração tamanho da imagem e conversão RGB	46
3.2	Código de alteração de informação de canais de cor	47
3.3	Script de extração de características	50
3.4	Script de classificação	51
C.1	Código fonte de extração de características	139

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
CONAB	Companhia Nacional de Abastecimento
DA	Data Augmentation
DNER	Departamento nacional de estradas de rodagem
DPI	Dots per inch
DT	Decision Tree
Embrapa	Empresa Brasileira de Pesquisas Agropecuárias
GLCM	Gray-level co-occurrence matrix
IBL	Instance Based Learner
IRC	Índices relativos de clorofila
KNN	K-nearest neighbor
LCAD	Laboratório de computação de alto desempenho
LDBP	Local direcional binary pattern
LPQ	Local Phase Quantization
MLP	Multi-layer perceptron
NB	Naive Bayes
NSCT	Non-subsampled contourlet transform
PDI	Processamento digital de imagens
RGB	Red, green, blue
RF	Random forest
RNA	Redes neurais artificiais
OpenCV	Open Computer Vision
SONDE	Self-organizing novelty detection
SVM	Support vector machine

SUMÁRIO

1	INTRODUÇÃO	17
1.1	OBJETIVO GERAL	19
1.2	OBJETIVOS ESPECÍFICOS	19
2	REVISÃO DA LITERATURA	20
2.1	AGREGADOS MINERAIS	20
2.2	CLASSIFICAÇÃO DE AGREGADOS	21
2.3	PAVIMENTO ASFÁLTICO	23
2.4	PROCESSAMENTO DIGITAL DE IMAGENS	24
2.5	ANÁLISE DE TEXTURA	25
2.5.1	Histograma	26
2.5.2	Matriz de Co-ocorrência	32
2.5.3	Local Binary Patterns	34
2.5.4	Local Binary Pattern Uniform	35
2.5.5	Entropia de Shannon	35
2.6	DATA AUGMENTATION	36
2.7	APRENDIZADO DE MÁQUINA SUPERVISIONADO	37
2.8	MEDIDAS DE AVALIAÇÃO DE DESEMPENHO	39
2.9	ANÁLISE ESTATÍSTICA DOS RESULTADOS	40
3	MATERIAL E MÉTODOS	41
3.1	AMBIENTE E CONFIGURAÇÃO	41
3.2	BASE DE IMAGENS	41
3.2.1	Basalto	41
3.2.2	Granito	42
3.2.3	Base Composta	43
3.3	CARACTERÍSTICAS DAS IMAGENS E ELIMINAÇÃO DE RUÍDO	43
3.4	PRÉ-PROCESSAMENTO	46
3.5	EXTRAÇÃO DE CARACTERÍSTICAS	46
3.6	DELINEAMENTO EXPERIMENTAL	48
3.7	APRENDIZADO SUPERVISIONADO DE MÁQUINA	49
3.7.1	KNN	49
3.7.2	Naive Bayes	50
3.7.3	Decision Tree	50
3.7.4	Multi-layer Perceptron	50
3.7.5	Random Forest	50
3.8	OBTENÇÃO DOS RESULTADOS	50

3.9	ANÁLISE ESTATÍSTICA DOS RESULTADOS	51
4	RESULTADOS	52
4.1	GRUPO A	52
4.1.1	Acurácia do Basalto - KNN	52
4.1.2	Acurácia do Basalto - Naive Bayes	53
4.1.3	Acurácia do Basalto - DT	54
4.1.4	Acurácia do Basalto - MLP	55
4.1.5	Acurácia do Basalto - RF	57
4.1.6	Acurácia do Granito - KNN	58
4.1.7	Acurácia do Granito - NB	59
4.1.8	Acurácia do Granito - DT	61
4.1.9	Acurácia do Granito - MLP	62
4.1.10	Acurácia do Granito - RF	64
4.1.11	Acurácia do Basalto + Granito - KNN	65
4.1.12	Acurácia do Basalto + Granito - NB	66
4.1.13	Acurácia do Basalto + Granito - DT	68
4.1.14	Acurácia do Basalto + Granito - MLP	69
4.1.15	Acurácia do Basalto + Granito - RF	70
4.2	GRUPO B	72
4.2.1	Acurácia do Basalto - KNN	72
4.2.2	Acurácia do Basalto - NB	73
4.2.3	Acurácia do Basalto - DT	74
4.2.4	Acurácia do Basalto - MLP	76
4.2.5	Acurácia do Basalto - RF	77
4.2.6	Acurácia do Granito - KNN	78
4.2.7	Acurácia do Granito - NB	79
4.2.8	Acurácia do Granito - DT	81
4.2.9	Acurácia do Granito - MLP	82
4.2.10	Acurácia do Granito - RF	83
4.2.11	Acurácia do Basalto + Granito - KNN	84
4.2.12	Acurácia do Basalto + Granito - NB	85
4.2.13	Acurácia do Basalto + Granito - DT	87
4.2.14	Acurácia do Basalto + Granito - MLP	88
4.2.15	Acurácia do Basalto + Granito - RF	90
4.3	CONSIDERAÇÕES FINAIS	92
5	CONCLUSÃO	99

REFERÊNCIAS	101
APÊNDICE A – ANÁLISES ESTATÍSTICAS - GRUPO A	106
APÊNDICE B – ANÁLISES ESTATÍSTICAS - GRUPO B	122
APÊNDICE C – CÓDIGO-FONTE	138

1 INTRODUÇÃO

O Brasil é um dos principais países produtores de alimentos e se mantém como um dos maiores exportadores, ao lado de Estados Unidos e Índia. Segundo a Companhia Nacional de Abastecimento (CONAB), a agropecuária brasileira tem se consolidado como umas das maiores provedoras de alimento para o mundo (CONAB, 2021). A expectativa da Empresa Brasileira de Pesquisas Agropecuárias (EMBRAPA), é de que o país supere os Estados Unidos e se torne o líder na exportação de grãos até o ano de 2025 (EMBRAPA, 2020).

As estradas são principal via de transporte em território nacional, para escoar a produção dos campos até as indústrias, ao mercado interno ou aos portos para exportação. Para que o transporte seja mais eficaz e atenda a demanda crescente, é necessário que as estradas sejam construídas dentro de padrões de qualidade que ofereçam resistência e segurança (BALBO, 2007).

As estradas são constituídas por um conjunto de diversas camadas sobre a superfície do solo, após a terraplanagem, as quais são denominadas pavimentos. Estes têm função de garantir melhores condições de tráfego e desempenho em termos de custos operacionais e de manutenção, além de proporcionar comodidade e segurança (BALBO, 2007). Um desafio enfrentado pela engenharia civil na construção de pavimentos asfálticos é a seleção de material apropriado (agregado mineral), para garantir segurança e resistência nas obras de pavimentação.

A extração do agregado mineral é feita em larga escala para atender ao mercado da construção civil, que utiliza este material para diversos fins, como cimento, concreto asfáltico, lastro ferroviário e base para rodovias (BALBO, 2007). Contudo, parte desse material pode apresentar alteração em seu estado mineralógico devido a ação do tempo, em um processo natural conhecido como intemperismo ou meteorização (FORMOSO, 2006), quando submetidos a condições diferentes daquelas onde foram originados.

A alteração em agregados minerais gera redução da durabilidade e da resistência e, conseqüentemente, nas obras onde forem empregados. Para evitar ou minimizar tal problema, utiliza-se material não alterado ou com alteração mínima baseado em critérios técnicos da engenharia civil.

Os processos tradicionais de seleção de material, de maneira geral, demandam tempo devido às análises laboratoriais às quais as amostras são submetidas e que geram custos para a indústria. O teste mecânico, por exemplo, é usado para detectar a redução da resistência mecânica do agregado por consequência da alteração causada por intemperismo (BARTLEY *et al.*, 2007). Ainda que esses processos tragam resultados satisfatórios para apoiar o processo de seleção, não é possível realizá-los em todo o material, limitando o processo às amostras. Diante disso, busca-se novas formas de realizar a classificação dos agregados de forma confiável, rápida e barata por meio da

computação. Um método alternativo que vem sendo estudado em diversas áreas do conhecimento é o processamento digital de imagens (PDI), largamente utilizado nas áreas de medicina, biologia, geologia, agronomia, entre outras, como ferramenta auxiliar de produção de conhecimento através de extração de características e reconhecimento de padrões (GONZALEZ; WOODS, 2009).

Em PDI, uma técnica que merece destaque é a análise de textura, que tem como principal objetivo encontrar objetos ou conceitos em uma determinada imagem. A detecção de defeitos de superfícies ou metais, análise de imagens médicas para detecção de células cancerosas, doenças ou classificação de espécies de plantas e reconhecimento de objetos são exemplos do uso da análise de textura (ARMI; FEKRI-ERSHAD, 2019).

Algoritmos de análise de textura como *Local binary patterns*, matriz de co-ocorrência, histograma de imagem e entropia são exemplos que podem ser explorados para buscar características que possam detectar alterações em imagens, seja através da cor ou da forma.

No setor de construção civil, pesquisas avaliaram técnicas de PDI para detecção de fissuras superficiais no concreto, obtendo resultados satisfatórios que facilitaram as tarefas de manutenção das obras (KASEKO; RITCHIE, 1993). Entretanto, ainda que com a ampla utilização, alguns problemas merecem investigação, a fim de comprovar sua eficiência.

Segundo Martins Edson Aparecido e Senger (2020) as alterações em certos tipos de agregados, geralmente, trazem alteração de cor, junto com a erosão e dissolução do material, aumento da porosidade e aumento do grau de rachaduras. Estes fenômenos aumentam o desafio da análise de textura em relação ao objetivo.

O presente trabalho busca investigar, através das imagens de agregados do basalto e do granito, uma alternativa aos métodos tradicionais, que possa se mostrar mais rápida, barata e confiável para classificar, de acordo com o grau de alteração, o material que pode ser utilizado nas obras de pavimentação, para destinação correta nas obras de engenharia de acordo com normas específicas.

1.1 OBJETIVO GERAL

O presente trabalho tem o objetivo de investigar a utilização de processamento digital de imagens e aprendizado de máquina para a classificação dos agregados e comparar os resultados obtidos com os métodos utilizados pela engenharia civil.

1.2 OBJETIVOS ESPECÍFICOS

- Identificar as técnicas de PDI que se apresentem adequadas para extração de características e análise de textura;
- Avaliar as técnicas aplicadas em busca do melhor desempenho na classificação dos agregados.

2 REVISÃO DA LITERATURA

2.1 AGREGADOS MINERAIS

Agregados minerais são materiais granulares, sem forma e volume definidos, de dimensões e propriedades estabelecidas para uso em obras de engenharia civil (VALVERDE, 2001). Eles são classificados quanto à origem, às dimensões das partículas, à massa unitária e composição mineralógica. O presente trabalho visa abordar agregados que pertencem ao grupo das rochas ígneas, como o basalto e o granito.


Para a construção de estradas utiliza-se diversos tipos de agregados minerais (fragmentos de rochas) nas diversas camadas que as compõem. O tipo de agregado deve ser cuidadosamente escolhido de modo que possua as propriedades apropriadas para a utilização a que se destina. Esses agregados devem oferecer resistência para que as estradas tenham maior durabilidade baseadas em especificações de acordo com o seu fim, e se apresentam de vários tipos, como: rochas metamórficas (mármore, xisto, ardósia), rochas ígneas (basalto, gabro e granito) e rochas sedimentares (calcário, arenito, folhelho) (GOUVEIA *et al.*, 2013).

Os agregados minerais tem suas dimensões e propriedades estabelecidas para uso em obras de engenharia civil, utilizando materiais tais como a pedra britada, areias naturais e o cascalho, além de argilas. Outra definição de agregado, segundo Michael (1960) é uma mistura de pedregulho, areia, pedra britada, escória ou outros materiais minerais usados na combinação com um ligante para formar concreto.

A extração de agregados minerais é feita em larga escala para atender ao mercado da construção civil e utiliza, entre outros materiais, agregado mineral para diversos fins, como cimento, concreto asfáltico e base para rodovias (GOUVEIA *et al.*, 2013).

O agregado mineral, quando exposto a um ambiente de condições adversas a aquela onde foi formado, pode sofrer um processo de alteração físico-química. Esse processo pode afetar o agregado a ponto de perder a resistência e durabilidade (alteração do agregado). Na figura 1, é possível perceber a diferença entre dois agregados de granito, onde o agregado A está alterado e o B não apresenta alteração.

Figura 1 – Exemplos de agregado de granito alterado (A) e não alterado (B).



Fonte: O autor (2021)

Para avaliar a resistência e durabilidade dos agregados, a Engenharia Civil utiliza alguns métodos, entre eles, o teste de abrasão de Los Angeles (WU; PARKER; KANDHAL, 1998) . Esse método mede o desgaste de um agregado por abrasão através do impacto entre agregados e esferas de aço padronizadas que giram num tambor com velocidade controlada, como mostra a figura 2. Logo após, o agregado é peneirado e pesado. O desgaste resultante não deve ser superior a 50% em massa do material inicial.

Figura 2 – Equipamento para ensaio de abrasão Los Angeles.



Fonte: Adaptado de BERNUCCI *et al.* (2008)

2.2 CLASSIFICAÇÃO DE AGREGADOS

O agregado mineral pode ser classificado em natural, artificial e reciclado (BERNUCCI *et al.*, 2008). O agregado natural é obtido de fontes naturais através de processos de desmonte, escavação e drenagem em depósitos continentais, marinhos, estuários e rios. O agregado artificial de origem mineral é resultante de um processo industrial envolvendo modificações térmicas, tais como a escória de alto-forno e de aciaria. Pode apresentar problemas de expansibilidade e heterogeneidade, requerendo tratamento adequado para utilização, porém podem apresentar alta resistência ao atrito.

O agregado reciclado é resultante do processamento de materiais inorgânicos usados na construção. A utilização de agregado reciclado reduz impacto ambiental aumentando o ciclo de vida dos materiais (BERNUCCI *et al.*, 2008).

Os agregados são classificados quanto ao tamanho, para uso em misturas asfálticas, em graúdo, miúdo e material de enchimento ou fíler:

- Graúdo – é o material com dimensões maiores do que 2,0mm, ou seja, retido na peneira nº 10. São as britas, cascalhos, seixos, etc.;
- Miúdo – é o material com dimensões maiores que 0,075mm e menores que 2,0mm. É o material que é retido na peneira de nº 200, mas que passa na de abertura nº 10. São as areias, o pó de pedra, etc.;

- Material de enchimento (filler) – é o material onde pelo menos 65% das partículas é menor que 0,075mm, correspondente à peneira de nº 200, e.g., cal hidratada, cimento Portland, etc. A tabela 1 relaciona as dimensões das aberturas das peneiras e seus respectivos números.

Tabela 1 – Dimensões das aberturas das peneiras


Vão da Peneira		Abertura da Peneira	
Padrão	Número	Milímetros	Polegadas
75,0mm		75,0	3,0
50,0mm		50,0	2,0
37,5mm		34,5	1,5
25,0mm		25,0	1,0
19,0mm		19,0	0,75
9,50mm		9,50	0,375
4,75mm	4	7,75	0,187
2,36mm	8	2,36	0,0937
2,00mm	10	2,00	0,0789
1,18mm	16	1,18	0,0469
600mm	30	0,600	0,0234
425mm m	40	0,425	0,0168
300mm m	50	0,300	0,0117
150mm m	100	0,150	0,0059
75mm m	200	0,075	0,0029

Fonte: Adaptado de BERNUCCI *et al.* (2008)

Outra classificação dos agregados refere-se à distribuição dos grãos que é determinada por meio de análise de peneiramento.

Amostras secas de agregado são separadas passando por diversas peneiras com aberturas que vão diminuindo de uma para outra, progressivamente, conforme a figura 3. Esse procedimento obedece a norma DNER-ME 035/95 (BRASIL, 2000).

Figura 3 – Análise por peneiramento




Fonte: Adaptado de BERNUCCI *et al.* (2008)

2.3 PAVIMENTO ASFÁLTICO

Para a construção do pavimento são utilizados, geralmente, dentre outros materiais, os agregados minerais que, segundo Petrucci e Paulon (1993), são materiais granulares, sem forma e volume definidos.

Os pavimentos asfálticos apresentam em seu revestimento uma mistura de agregados e ligantes asfálticos. Suas principais camadas possuem revestimento asfáltico na camada superior, base, sub-base, reforço do subleito e subleito, conforme mostra a figura 4. Seguem mais detalhes de cada camada (BALBO, 2007).

Figura 4 – Estrutura do pavimento



Fonte: Adaptado de BERNUCCI *et al.* (2008)

Revestimento: Uma das funções principais do revestimento é receber a carga sem sofrer deformações elásticas horizontais ou verticais, perda de compactação e desagregação. Logo, o revestimento deve ser composto de material que evite a movimentação horizontal, além de ser bem aglutinado. Os paralelepípedos, blocos pré-moldados de concreto e concreto compactado com rolo são exemplos de materiais que oferecem essas condições. Outra função importante do revestimento é a impermeabilização do pavimento (BALBO, 2007).

Base e Sub-bases: Segundo BALBO (2007), os esforços verticais transmitidos ao subleito devem ser compatíveis com a sua capacidade de resistir-lhes. Logo, as camadas de base e sub-base servem para aliviar as pressões sobre as camadas inferiores. A base é a camada que fica logo abaixo do revestimento do pavimento. Exige que se tenha uma qualidade boa para que o pavimento não sofra dano com a carga imposta. Sua constituição geralmente traz mistura de solo e agregados (solo-brita), brita graduada, brita graduada tratada com cimento, solo estabilizado quimicamente com ligante hidráulico ou asfáltico, concretos, etc. A drenagem subsuperficial dos pavimentos também é feita pelas camadas de base e sub-base (BALBO, 2007).

Reforço de subleitos: Camada de espessura constante geralmente construída acima da regularização. É uma camada não obrigatória, pois outras camadas superiores mais espessas podem, em tese, aliviar as pressões sobre um subleito medíocre (BALBO, 2007).

Subleitos: É o terreno de fundação onde será construído o pavimento. Sua constituição é de material natural consolidado e compactado ou por material transportado e

compactado, quando se trata de aterro. A superfície do subleito deve ser regularizada de acordo com o projeto do pavimento (BALBO, 2007). O pavimento asfáltico, como já citado, deve proporcionar segurança e para garantir isso é importante que seja construído com material adequado. O agregado mineral escolhido para esse propósito deve ser avaliado previamente através de amostras para verificar presença de alteração.

Paralelamente aos conceitos e métodos utilizados pela engenharia civil para classificar agregados para suas diversas finalidades na construção de estradas, surgem estudos na área da computação com o objetivo de investigar ferramentas que disponibilizem alternativas aos métodos tradicionais. Algumas ferramentas que já estão sendo utilizadas como PDI, extração de características e análise de textura.

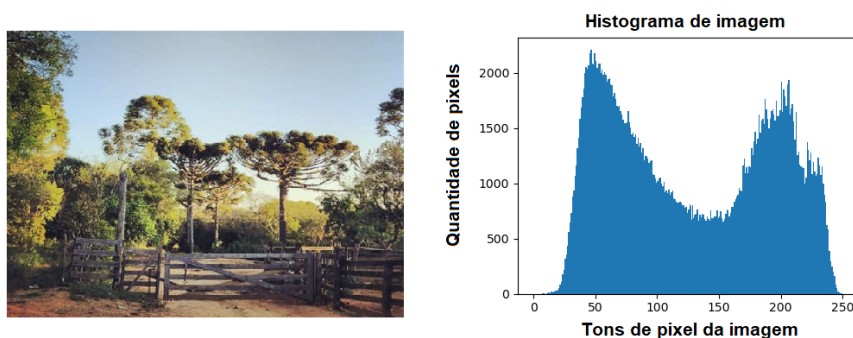
2.4 PROCESSAMENTO DIGITAL DE IMAGENS

O processamento digital de imagens pode ser definido como sendo um conjunto de processos onde, a partir de imagens ou vídeo, são realizadas alterações ou extração de características para determinado fim, como reconhecimento de objetos (GONZALEZ; WOODS, 2009). A partir de qualquer imagem é possível extrair seu histograma para futura análise. Histogramas de imagens são gráficos que demonstram a frequência que determinada cor de pixel apresenta em relação à imagem.

Baseado na análise de um histograma é possível determinar se a imagem é mais escura (valores mais baixos no eixo X) ou clara (valores mais altos no eixo X) ou uma, ainda, imagem predominantemente cinza (quando a distribuição se concentra mais ao centro do gráfico para o eixo X (GONZALEZ; WOODS, 2009). Histogramas podem, também, permitir a extração de informações.

A figura 5 traz uma imagem e seu respectivo histograma, onde é possível perceber que os tons mais escuros (próximos ou igual a zero) e mais claros (próximos ou igual a 255) aparecem em menor número em relação aos valores centrais, mantendo uma frequência distribuída em todas as escalas.

Figura 5 – Exemplo de histograma



Fonte: O Autor (2021)

A partir de dados de histogramas é possível extrair novas informações a fim de auxiliar no processo de reconhecimento de padrões, utilizando técnicas como a extração de características e análise de texturas.

Extração de características é o processo pelo qual os dados de entrada de uma imagem ou vídeo investigado são extraídos em um conjunto de características específicos para o que se deseja investigar. Esse processo resulta de um conjunto reduzido, diminuindo a dimensionalidade dos dados e o custo computacional e criando novos atributos a partir das características originais (KHALID; KHALIL; NASREEN, 2014). A tarefa de extração de características pode ser realizada através de diversas ferramentas de PDI que buscam as informações mais relevantes do objeto investigado e é empregada, geralmente, como ferramenta auxiliar dos processos de análise de textura (seção 2.5).

2.5 ANÁLISE DE TEXTURA

A análise de textura de uma imagem tem por objetivo estudar as propriedades da superfície de um objeto, entender como seres humanos percebem as diferentes texturas e, a partir disso, modelar algoritmos que possam reconhecer a imagem com a mesma percepção humana (KARU; JAIN, 1996). Segundo Oliveira *et al.* (2014) padrões de textura trazem informações sobre a distribuição espacial, luminosidade e arranjo estrutural da superfície em relação às regiões vizinhas.

Outra definição para textura é apresentada por Pedrini e Schwartz (2008), ressaltando que esta contém informações sobre a distribuição espacial, variação de luminosidade, suavidade, rugosidade e regularidade, descrevendo o arranjo estrutural das superfícies e as relações entre regiões vizinhas. Diversos tipos de textura, algumas com padrões bem definidos em contraste com outras que apresentam textura irregular como mostrado na figura 6.

Figura 6 – Diferentes tipos de texturas



Fonte: O Autor (2021)

A análise de textura de agregados por meio de PDI tem sido investigada na literatura em trabalhos que abrangem diversas áreas de conhecimento.

Em Mangulkar, Ghosh e Jamkar (2019), os autores apresentam um sistema para estimar características de agregados usando técnicas de PDI, que consiste em transportar o agregado em plataforma giratória, sistema de iluminação, aquisição de imagem e controle integrado entre si.

Neste processo, os agregados são encaminhados a uma esteira e, então, a uma plataforma giratória onde são capturadas imagens com câmeras de 8 megapixels de resolução. Diversas imagens são capturadas em diversos ângulos para que todo o agregado seja capturado nas imagens. Os autores utilizaram quatro categorias diferentes de agregados; alongado, arredondados, angular e cilíndrico.

Foi concluído que utilizando técnicas de processamento digital de imagem foi possível estimar dimensões mais longas, intermediária e mais curta das partículas de agregado.

2.5.1 Histograma

Histogramas são comumente usados para representar características da composição de uma imagem, além de serem invariantes a rotação e translação, por isso são considerados fáceis de indexar e recuperar imagens. O histograma de uma imagem, em nível de cinza, pode ser representado pela função discreta:

$$h(r_k) = n_k, \quad (2.1)$$

onde r_k é a quantidade de níveis de cinza e n_k é o número de pixel que um nível de cinza possui. A partir do histograma de uma imagem, diversas medidas estatísticas podem ser obtidas como valor médio, desvio padrão, variância e valor mínimo e máximo.

O algoritmo 1 faz cálculo de histograma para uma determinada imagem. O cálculo é feito da seguinte forma: Cria-se um vetor de 256 posições e atribui-se 0 em todas as posições do vetor. Na sequência, percorre-se a imagem e para cada nível de cinza encontrado, soma-se o valor 1 ao seu respectivo valor no vetor. Ao final, tem-se um vetor com a quantidade de cada nível de cinza onde é possível montar o histograma. Considerando que H é o total de tons de cinza, $imagem$ é o vetor que contém todos os valores de H , $pixel$ é o valor do tom de cinza em cada posição da imagem e L é o tamanho máximo do vetor.

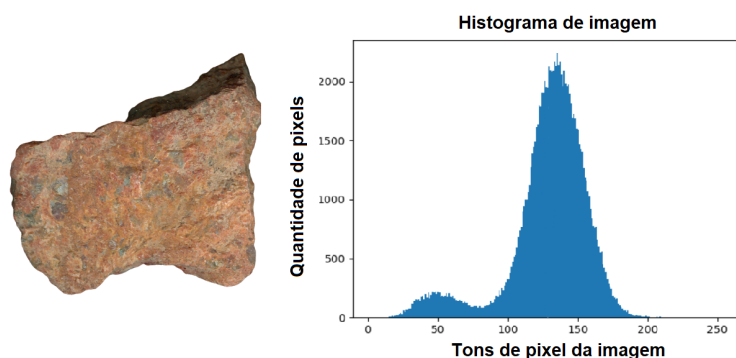
Analisando um determinado histograma pode-se concluir que a imagem é predominantemente escura, quando os tons de cinza são de valores próximos ao zero, ou mais clara, trazendo tons de cinza mais próximos a 255.

Algoritmo 1: Algoritmo de histograma

Result: Cria o histograma
 Inicia o vetor com valor 0;
for $i = 0$ até $L_{max}-1$ **do**
 | $H[i] = 0$
end
 Calcula cada nível de cinza;
for $x = 0$ até $Lin - 1$ **do**
 | **for** $y = 0$ até $Col - 1$ **do**
 | | $intensidade = imagem[x,y]$
 | | $H[(intensidade)] = H[(intensidade)] + 1$
 | **end**
end

A figura 7 demonstra o histograma de uma imagem onde os tons de cinza estão equilibrados no centro do histograma. Analisando o histograma, pode-se perceber que a imagem não apresenta tons totalmente claros e/ou escuros.

Figura 7 – Histograma de uma imagem de agregado



Fonte: O autor .

Alguns estudos utilizando histograma foram realizados para segmentar imagens de insetos como em Rajinikanth e Couceiro (2015), no qual os pesquisadores conseguiram classificar várias espécies de insetos analisando imagens com auxílio de técnicas de segmentação e aprendizado de máquina. Outra área que se beneficia das técnicas de histograma RGB é a agricultura, onde o trabalho de Ali *et al.* (2017) contribuiu para a detecção de doenças cítricas baseado em sintomas em várias plantas. Já na pesquisa de VijayaLakshmi e Mohan (2016) foi empregado o uso histograma RGB para classificar folhas de plantas auxiliado por matriz de co-ocorrência e local binary pattern no processo de extração de características, que são ferramentas abordadas neste trabalho.

Em Martins Edson Aparecido e Senger (2020) foi proposta a investigação de intemperismo de agregados basálticos através de análise de textura. Os autores utilizaram 202 amostras de agregado alterado e 251 amostras não alteradas, ambas de

basalto. As amostras foram digitalizadas em um *scanner* de mesa de 4800 dpi, em uma resolução de 300 dpi em ambiente escuro. Os descritores utilizados foram histograma RGB, histograma a nível de cinza, LBP, o *Local Phase Quantization* (LPQ) e a entropia RGB. O processamento das imagens foi realizado com o uso da biblioteca OpenCV usando a linguagem C.

A tarefa de classificação foi realizada utilizando o software Weka. Os algoritmos de aprendizado de máquina utilizados foram *Naive Bayes* (NB), Instance Based Learner (IBK), J48 e *Multi-layer Perceptron*. Os algoritmos foram comparados usando o teste T, que compara o desempenho dos algoritmos de *machine learning*. A acurácia foi de 95%. Os melhores resultados foram observados quando se utilizou as informações do canal R nos algoritmos *Multilayer Perceptron* (MLP), Instance-based learning (IBL) e *Naive Bayes*. Todos os classificadores apresentaram igual desempenho quando utilizado o canal G. Para o canal B, todos foram estatisticamente iguais, exceto o *Naive Bayes*. Para as informações de entropia e histograma LBP, o melhor desempenho foi apresentado pelo MLP em relação aos outros classificadores. Os pesquisadores concluíram que a utilização de histograma de cores e os descritores LBP uniforme e LBP invariante a rotação são descritores promissores no propósito de detecção de alteração.

Outro trabalho que envolve resolução de problemas na área de pavimentação foi proposto por Gouveia *et al.* (2015) no qual os autores buscaram determinar a forma dos agregados através de esqueletização multiescala. Métodos tradicionais da engenharia civil são trabalhosos e demorados. A proposta dos autores foi criar um método rápido e objetivo para classificar os agregados quanto sua forma. Foram utilizados dois tipos de agregados (basalto e seixo) e 100 amostras de cada tipo. Os algoritmos de classificação utilizados foram IBK, *Naive Bayes* e J48. O melhor valor absoluto foi obtido para um valor de limiar igual a 5, que produz um índice de acerto na classificação igual a 96,85%. Os descritores utilizados se mostraram promissores na tarefa de análise de forma.

A proposta de Gouveia *et al.* (2011) foi classificar partículas de agregados de basalto baseado nas propriedades de textura. A hipótese foi testar ferramentas de classificação aliadas a técnicas de textura de imagens a fim de classificar agregados em alterados e não alterados. O método utilizado foi a aquisição das imagens de agregados e processamento, cálculo de medições relacionadas à textura, classificação de características para seleção dos atributos mais importantes e classificação através de diferentes abordagens para determinar o método mais preciso.

A aquisição de imagens foi realizada colocando as amostras em um *scanner* com uma resolução de 300 DPI (*dots per inch*) em ambiente escuro. Para a eliminação do fundo usou-se a técnica de detecção de bordas *border-following*. Para análise de histogramas os autores utilizaram imagens em tons de cinza visto que imagens coloridas obtiveram resultados similares.

O passo seguinte foi selecionar características a fim de reduzir custo computacional. Os classificadores *Multi-layer perceptron*, *Naive bayes*, *K-nearest neighbor*, *Decision tree* e *Random forest* foram avaliados.

O melhor resultado foi apresentado pelo KNN que atingiu 99,4% de acerto considerando todos os atributos. Concluiu-se então que as técnicas de PDI com os classificadores são capazes de classificar os agregados de rochas em alterado e não alterado, mesmo que certo nível de ruído esteja presente.

Os autores sugerem que agregados de origens diferentes podem ser estudados utilizando outros níveis de alteração possíveis.

No trabalho realizado por Gouveia *et al.* (2011), buscou-se analisar e classificar agregados de mineral através da abordagem baseada em entropia. Para realizar o estudo foram obtidas imagens de 300 DPI em ambiente escuro para evitar ruído luminoso.

Após obter todas as imagens necessárias, as mesmas foram submetidas à técnicas de PDI como *thresholding* para retirar o *background* e dilatação. Aplicou-se algoritmos para detectar bordas da área de interesse, separando a imagem do agregado e o fundo da imagem.

Os histogramas foram usados para verificar a frequência relativa de ambas as escalas cinzas e coloridas. No total três histogramas para cada imagem foi obtida representando as cores que compõem o RGB. Duas abordagens de classificação foram adotadas, a ART (*adaptive resonance theory*) 2A-E (CARPENTER; GROSSBERG; ROSEN, 1991) e SONDE (Self-organizing novelty detection) (ALBERTINI; MELLO, 2007). Após a classificação de todos os agregados em alterado e não-alterado, os autores realizaram a classificação do nível de alteração com o conjunto de imagens de agregados alterados.

Os autores indicam que a abordagem de classificação de agregados de rochas em alterados e não alterados é possível utilizando entropia bem como classificação em sub-classes.

O trabalho de Vázquez *et al.* (2011) investigou o uso de PDI para identificação de alteração em pedras por eflorescência. O estudo realizado em uma capela localizada em uma cripta na Espanha. As amostras estudadas foram retiradas do calcário de cores diferentes (bege e verde). Descrição petrográfica, análises químicas e mineralógica foram realizadas, através de microscópio NIKON e espectrômetro PERKIN ELMER e um *scanner* eletrônico com raio X. Os autores utilizaram um sistema compacto chamado GEOJARS-10, da empresa Microm España, S.A. e um computador Kontron AT. O processamento de imagem foi realizado em 8 imagens preto e branco. A técnica chamada *threshold* foi aplicada para separar as pedras (preto) da eflorescência (branco).

A conclusão dos autores para a pesquisa indica que as técnicas de PDI são capazes de detectar e classificar o processo de degradação das pedras. Imagens em

preto e branco permitem reconhecer e separar as formas de intemperismo causados por eflorescência

No trabalho de Barmpoutis *et al.* (2018) foi proposta uma nova abordagem de reconhecimento de espécies de madeira, de forma automática, através de análise de textura multidimensional. Foi criado um *dataset* chamado "wood-auth" que continha 4200 amostras de 12 espécies de madeira. Para cada imagem foram concatenadas as informações de histograma vertical e horizontal, o que foi chamado de descritor V-H. Para classificar foi utilizado o classificador *Support vector machines* (SVM).

Optou-se por usar imagens coloridas ao invés de usar escala de cinza. As imagens foram divididas em trechos verticais e horizontais de tamanhos que variam de acordo com a dimensão da imagem. Com isso foram criados livros de código (*codebooks*) para horizontal e vertical e, através deles extraídas informações dinâmicas e de aparência. A classificação foi feita usando Redes neurais convolucionais. A pesquisa apresentou resultados superiores a 90% de acurácia para todos os métodos, mostrando taxas de classificação alta para todas as espécies.

O objetivo de Hiremath e Bhusnurmath (2017) foi investigar descritores *Local directional binary pattern* (LDBP) multi resolução para classificação de textura usando difusão anisotrópica para imagens de madeira. A pesquisa foi baseada em 4 conjuntos de dados de textura (*Brodatz, Oulu, VisTex, Kylberg*). Foram investigados três métodos chamados de método 1 que se baseia difusão anisotrópica e multi-resolução, método 2 baseado em NSCT *non-subsampled contourlet transform* (*Haralick features*) e características LBDP e método 3 baseado em NSCT (*haralick features* e média) e LBDP. As informações foram extraídas das imagens pelo descritor LBDP, usando características de Haralick como homogeneidade, entropia, contraste, energia e probabilidade máxima, para os ângulos 0, 45, 90 e 135 graus. O classificador KNN foi utilizado baseado na distância euclidiana. Os resultados para os três métodos adotados apontaram uma acurácia acima de 95%, porém o método 1, proposta do autor, teve o tempo de treinamento e teste reduzido em relação aos métodos 2 e 3. A hipótese dos autores se mostrou efetiva para aplicação industrial chamada de '*wood identification*'.

A utilização de técnicas de PDI e aprendizado de máquina tem sido usado amplamente em diversos trabalhos acadêmicos, em especial no programa de pós-graduação em computação aplicada, reforçando que a utilização de tais técnicas traz resultados positivos na produção de conhecimento.

Em Barros (2013), o autor propôs a análise de nitidez em métodos de classificação de imagens de madeira, nas quais buscou utilizar técnicas de processamento digital de imagens para o reconhecimento de espécies de madeira. Para realizar o trabalho foi utilizado um banco de imagens de 19 espécies de madeira de onde foram extraídas suas características como a cor (utilizando o modelo de cor RGB (Red, Green, Blue), o LBP (que é um método que transforma a imagem em um vetor), o LBP uniforme (que

considera a quantidade de transições que ocorrem em cada padrão de textura). O autor fez uso, também, do método de *Tenengrad*, que é um método que mede o nível de nitidez baseado na magnitude do gradiente da imagem.

Os testes foram realizados utilizando redes neurais para classificar imagens em suas determinadas classes, com índice de nitidez definido em pouca nitidez e alta nitidez. As imagens foram divididas em zonas de tamanho igual, as quais foram chamadas de janelas. Foram adotadas divisões com janelas de 12, 24, 36 e 48 por amostra. Segundo o autor, a análise de nitidez trouxe melhora nos resultados e a combinação de RGB + LBPU na divisão de 36 janelas com classificação por voto majoritário (onde cada janela terá um voto, de acordo com a classificação obtida e a maior votação determinará a qual classe a amostra pertence) e desconsiderando as amostras de baixa nitidez.

Em Caldas (2014), a autora propôs a avaliação de metodologia de aquisição de imagens para verificar a qualidade de sementes de milho. Para tal, utiliza de técnicas básicas de PDI. O objetivo foi garantir um padrão na aquisição das imagens sem interferências externas. Os materiais utilizados foram duas sementes de milho para procedimentos de luz natural e outras três sementes para luz controlada. Tendões de luz foram construídas para controle de iluminação e a adaptadas para cada tipo de câmera utilizada. Foram utilizados dois tipos de câmeras, sendo uma câmera Kodak EasyShare M531 – 14 Mega Pixels e outra Canon Professional T5i - Rebel.

Após a captação das imagens, empregou-se técnicas de interseção e correlação de comparação de histogramas destas. Cerca de seis mil imagens foram capturadas. Os resultados apontaram que a captura das imagens sem o uso de flash apresentou maior igualdade (interseção) do que as imagens capturadas com o uso de flash. As imagens obtidas sem flash apresentaram maior semelhança (correlação).

O trabalho reforça a necessidade de se adquirir as imagens de forma a evitar que informações errôneas sejam extraídas pelos sistemas computacionais, por exemplo, brilho seja confundido com doença na semente, e por consequência gerar falso positivo ou falso negativo.

Em Andrade (2015), foi proposto utilizar técnicas de processamento digital de imagem para a obtenção de índices relativos de clorofila (IRC), que são correlacionados com atributos nutricionais das plantas. Utilizando apenas a região de interesse da folha da planta foi aplicado particionamento de imagem. O experimento consistiu em coletar dados (imagens e dados de comprimento de onda) em uma área de 2000 metros quadrados de uma cultura de milho, em um intervalo de horas durante o dia entre a manhã e início da noite.

Com os dados em mãos, o autor aplicou as técnicas de processamento digital de imagens, obtendo os dados apenas da área de interesse em cada imagem e posteriormente aplicou algoritmos de mineração de dados para tentar alcançar êxito

no que foi inicialmente proposto. O resultado apresentado pelos autores mostrou êxito em utilizar processamento digital de imagem para estimar teor de Nitrogênio foliar na cultura do milho.


A seguir serão detalhadas as ferramentas de textura de imagem que pretende-se utilizar nesta pesquisa: a matriz de co-ocorrência (seção 2.5.2), o padrão binário local (LBP) (seção 2.5.3), o padrão binário local uniforme (LBPU) (seção 2.5.4) e a entropia (seção 2.5.5).

2.5.2 Matriz de Co-ocorrência

Matriz de co-ocorrência, também chamada de *Gray-level co-occurrence matrix* (GLCM) Haralick, Shanmugam e Dinstein (1973) consiste em um método estatístico que pode ser empregado em análise de textura de imagens. Esse método descreve a distribuição dos pixels em tons de cinza e retrata a relação espacial desses pixels na imagem (AZEVEDO; CONCI, 2003). A GLCM baseia-se na estatística de co-ocorrência e é amplamente empregada na extração de descritores de textura de uma imagem, por exemplo para fins de classificação como sugerem Cai-xiang e Shu-bo (2009).

A construção da matriz de co-ocorrência é dada a partir das informações de distância e ângulo de um determinado pixel central e seus vizinhos. Para uma imagem de 3 pixels de largura por 3 pixels de altura, ou seja, uma matriz 3x3, considerando o pixel central P , seus vizinhos serão os pixels imediatamente ao redor como demonstrado na figura 8. O ângulo varia de 0° a 270° e a distância pode variar até o limite da imagem.

Figura 8 – Ângulos para cálculo da matriz de co-ocorrência



Fonte: Adaptado de (ITO; KIM; SALCEDO, 2009).

A expressão que define uma matriz de co-ocorrência é definida como:

$$P_{ij} = \frac{M_{ij}}{\sum_{i,j=0}^{N-1} (M_{ij})} \quad (2.2)$$

Onde:

- i e j são números da linha e coluna, respectivamente
- M é o valor da célula (i, j)

- P_{ij} é a probabilidade da célula (i, j)
- N é o número de linhas ou colunas, uma vez que M é uma matriz quadrada

Uma GLCM baseia-se no conceito de dependência espacial dos níveis de cinza da imagem que resulta em uma matriz que incorpora informação da relação dos pixels e sua vizinhança. Haralick e Shapiro (1992) e Haralick (1979) sugerem diversos descritores de textura, dos quais seis serão utilizados nessa pesquisa:

- Energia ou segundo momento angular: é uma medida do nível total de intensidade. A expressão da energia é definida como:

$$Ene = \sum_{i,j=0}^{N_g-1} (C_{ij})^2. \quad (2.3)$$

- Contraste: traz a medida de similaridade da intensidade do pixel em relação aos pixels vizinhos e é definido pela expressão

$$Con = \sum_{i,j=0}^{N_g-1} |i - j|^k (C_{ij})^l, \quad (2.4)$$

em que $k \geq 1$ define o quão rápido a medida varia com a distância da diagonal. Para $k = 1$ e $l = 1$ essa medida se torna uma medida de dissimilaridade de primeira ordem (RAMALHO, 2013).

- Entropia: busca a medida da aleatoriedade ou desorganização dos níveis de cinza da imagem. É descrita da seguinte maneira:

$$Ent = - \sum_{i,j=0}^{N_g-1} C_{ij} \ln(C_{ij}). \quad (2.5)$$

- Correlação: mede a probabilidade de ocorrência de pares de pixels. A correlação é atribuída por:

$$Cor = \sum_{i,j=0}^{N_g-1} \frac{ijC_{ij} - \mu_i\mu_j}{\sigma_i\sigma_j}, \quad (2.6)$$

- Homogeneidade: mede o quanto a distribuição dos elementos da GLCM está próxima da diagonal e é definida pela expressão

$$Hom = \sum_{i,j=0}^{N_g-1} \frac{C_{ij}}{1 + |i - j|}, \quad (2.7)$$

Onde:

- C_{ij} é o elemento ij da matriz simétrica
- N é número de tons de cinza da imagem
- μ a média GLCM (sendo uma estimativa da intensidade de todos os pixels nas relações que contribuíram para o GLCM)
- σ a variação de intensidade de todos pixels.

Algumas pesquisas foram realizadas utilizando GLCM para investigar problemas nas áreas de engenharia de produção como em Gadelmawla (2004) que investigou um sistema de visão computacional para caracterização de superfícies rugosas.

Outro trabalho que utiliza GLCM, realizado por Oliveira *et al.* (2012), investigou a classificação de folhas de eucalipto de seis espécies distintas, fortalecendo o uso de PDI na área de biologia. Na área da saúde, GLCM foi utilizada para detectar fraturas em ossos a partir de imagens de exames de raio-x (CHAI *et al.*, 2011).

Os autores Moya *et al.* (2019) utilizaram matriz de co-ocorrência em nível de cinza na investigação de edifícios colapsados. O desempenho da GLCM será avaliado no presente estudo como também o Local Binary Pattern (seção 2.5.3), outro descritor utilizado como ferramenta para extração de características.

2.5.3 Local Binary Patterns

O descritor *Local Binary Patterns* (LBP) foi introduzido por Ojala, Pietikäinen e Harwood (1996). O LBP considera o pixel central e seus vizinhos como sendo uma matriz 3x3, como mostra a figura 9 onde os pixels recebem valor 0 ou 1 dependendo do valor do ponto central.

Figura 9 – Exemplo de vizinhança 3x3 - LBP


g_1	g_2	g_3
g_4	g_c	g_5
g_6	g_7	g_8

Fonte: Adaptado de Negri (2017).

No processo LBP, ilustrado pela figura 10, quando o valor do pixel central for g_c (valor do pixel central) e o seu vizinho contiver valor maior/igual que g_c , este receberá o valor 1; caso o valor seja menor que g_c então receberá valor 0. Este processo é chamado de limiarização e se repete para toda a vizinhança.

Na primeira matriz (a) os valores dos pixels são comparados baseados no pixel central, gerando a matriz (b) com valores 0 e 1. A matriz (c) recebe os pesos dados aos

Figura 10 – Processo de limiarização - LBP



Fonte: Adaptado de Negri (2017).

pixels correspondentes. Na sequência, na matriz (d) os valores são somados onde os valores dos vizinhos forem diferente de 0, para esse exemplo o valor LBP será 169 que é a soma de $1+8+32+128$. Esse processo originou a seguinte equação para o LBP:

$$LBP = \sum_{i=1}^8 s(g_i - g_c) 2^{i-1}, \quad s(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (2.8)$$

Alguns métodos foram derivados do LBP original, como o LBP invariante a rotação e o LBP uniforme. Há também a possibilidade de aplicar os métodos LBP sobre imagens como sugere Zhu, Bichot e Chen (2010), combinando textura e cor.

2.5.4 Local Binary Pattern Uniform

A definição de LBP Uniforme foi proposta por Ojala, Pietikainen e Maenpaa (2002) e considera valor de transição, no padrão de textura, uniforme quando ocorre a saída de 0 para 1 ou de 1 para 0 até duas vezes, por exemplo 00011100, em que ocorrem duas transições e em 00000000, que não apresenta transição. Para alguns padrões que apresentam mais de 2 transições como em 00110100 ou 11001011 não se pode considerar uniformes. Considerando que um pixel central tem 8 vizinhos (considerando 1 pixel de distância), tem-se $2^8=256$ padrões existentes, onde 58 são considerados uniformes. Segundo Ojala, Pietikainen e Maenpaa (2002) esse padrão binário uniforme pode ultrapassar 90% de frequência na textura.

A textura de imagem pode ser analisada, ainda, com a utilização da entropia, próximo assunto abordado na seção 2.5.5.

2.5.5 Entropia de Shannon

Outro descritor que pode ser usado para caracterizar texturas de imagens é a entropia de Shannon, proposta por Claude Shannon em 1948 (SHANNON, 1948). Entropia (ou incerteza) busca medir a quantidade de informação transferida por um canal ou gerada por uma fonte. Quanto mais informação um canal possuir, maior será a incerteza ou entropia. Uma imagem que possui apenas um tom de cinza, por exemplo,


apresentará uma entropia de valor 0. Já para uma imagem que contenha dois tons de cinza a entropia será de valor 1. Dessa forma, quanto mais informação, maior será a entropia (PINEDA *et al.*, 2006).

A entropia pode ser representada pela equação 2.9, onde N é o número total de tons diferentes na imagem, p_i é a probabilidade do i -ésimo tom ser utilizado novamente.

$$H = - \sum_{i=0}^N p(i) \ln p(i), \quad (2.9)$$

A entropia não traz informações relativas à distribuição espacial na imagem. Portanto imagens diferentes podem apresentar a mesma entropia. Na imagem 11, é possível observar, à esquerda (A), a imagem com dois tons de cinza e à direita (B) a mesma imagem rotacionada.


Figura 11 – Imagem com dois tons de cinza. Entropia = 1,00



Fonte:O autor (2021).

A entropia de ambas as imagens equivale a 1,00. No exemplo da imagem 12 que contém muito mais tons de cinza, a entropia traz o valor de 6,26, justamente pelo fato de ter mais informações no canal.

Figura 12 – Imagem com diversos tons de cinza. Entropia = 6,26



Fonte:O autor (2021).

A análise de textura tem sido estudada em diversas áreas de PDI, conforme os trabalhos referenciados aqui. A tabela 2 mostra, de forma resumida, os principais métodos empregados em algumas pesquisas citadas:

2.6 DATA AUGMENTATION

De acordo com Taylor e Nitschke (2017), para classificação de imagens, na área de aprendizado de máquina, quanto maior a quantidade de amostras, maior a

Tabela 2 – Resumo de pesquisas

Pesquisa	Método	Algoritmo	Objeto	Resultado
Martins Edson Aparecido e Senger (2020)	RGB, LBP, LPQ e entropia	Naive Bayes, IBK e J48	Agregados de basalto	95% de acurácia
Hiremath e Bhusnurmath (2017)	LBP, LDBP	KNN	Imagens de madeira	95% de curácia
Barros (2013)	RGB, LBP, LBPU	MLP	Imagens de madeira	75,25% de taxa de acerto
Gouveia <i>et al.</i> (2011)	Entropia	MLP, Naive Bayes, KNN, Random Forest	Agregados de basalto	99% de acerto

Fonte:O autor (2021).

capacidade de predição dos classificadores. No entanto, a obtenção de uma quantidade significativa de amostras nem sempre é viável, se tornando uma tarefa difícil principalmente quando a obtenção das imagens depende de fatores diversos, como a coleta de imagens de satélites, onde cada imagem pode ser obtida apenas uma vez por dia, ou ainda, na obtenção de imagens de plantações em seus diferentes estádios de crescimento, onde o tempo pode variar de acordo com a cultura.

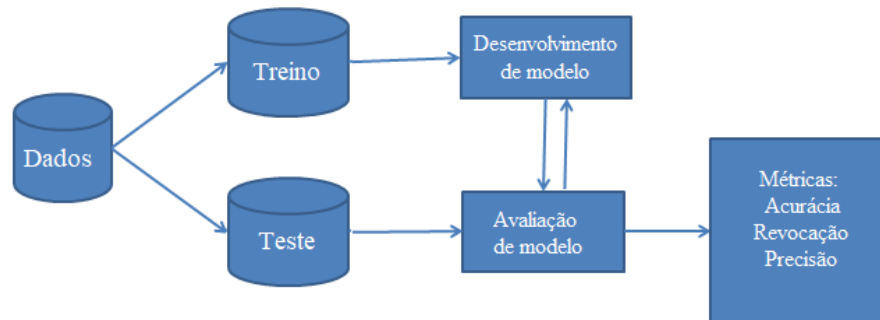
Para contornar tais limitações, algumas técnicas podem ser utilizadas, como a abordagem de *Data Augmentation* (DA). Essa abordagem consiste em aumentar a base de dados através de técnicas computacionais, com o objetivo de melhorar os resultados esperados (TAYLOR; NITSCHKE, 2018).

Uma das técnicas computacionais que a DA permite é a transformação no espaço de cores, onde é possível alterar informações de cores ou luminosidade e contraste sem que as características principais da imagem sejam alteradas (SHORTEN; KHOSHGOFTAAR, 2019) e assim aumentar o número de amostras de imagem. Optou-se por alterar a luminosidade das imagens neste trabalho.

2.7 APRENDIZADO DE MÁQUINA SUPERVISIONADO

A tarefa de classificação de dados supervisionada, em aprendizado de máquina, busca separar em grupos previamente definidos os elementos que possuem características definidas pelo modelo computacional empregado. A imagem 13 traz um fluxograma do processo de treino (*train*) e teste (*test*) de uma base de dados em *machine learning*. Essa tarefa permite que os classificadores sejam treinados com parte da base para posteriormente, realizar a classificação com base no que foi previamente aprendido. Nesse experimento, foi utilizado treino e teste para cada grupo no processo de classificação.

Figura 13 – Fluxograma de classificação com treinamento e teste



Fonte: O Autor (2021)

Existem muitas técnicas de classificação em *machine learning*, onde cada uma pode ser empregada para melhor êxito, de acordo com o objeto estudado. Nesse trabalho, cinco técnicas diferentes foram postas à prova.

- K-nearest neighbor (KNN): Esse classificador utiliza, necessariamente, um valor atribuído ao número de vizinhos que serão considerados para classificação e um valor para a distância do nó até seus vizinhos. O cálculo da distância pode ser realizado com base em diversas métricas de distância. A distância euclidiana, Minkowsky e Chebyshev são exemplos de medidas conhecidas. A distância euclidiana, escolhida para este trabalho, pode ser expressa da seguinte forma:

$$D(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (2.10)$$

onde p e q são as coordenadas, n é o número de dimensões e i a dimensão corrente. O algoritmo KNN calcula os dados, com base na distância e no número de vizinhos, atribuindo um rótulo para cada elemento (JENA; MOHANTY; MOHANTY, 2021).

- Árvore de decisão: *Decision Tree* (DT), em inglês, é um algoritmo de aprendizado de máquina supervisionado conhecido pela robustez e eficiência de aprendizagem (CHEN *et al.*, 2014). DT se baseia na ideia de divisão dos dados em grupo homogêneos. Classificação e regressão são cenários onde podem ser empregados o uso de árvores de decisão. Algumas características das árvores de decisão são entendimento fácil, aceitam dados categóricos e numéricos. Pode ocorrer *overfitting* (ou sobreajuste) onde a árvore se ajusta aos dados de treino perdendo performance nos dados de teste (CERVANTES *et al.*, 2015).
- Random Forest (RF): É uma coleção (ou conjunto) de classificação ou regressão, treinada em um *dataset* de mesmo tamanho do conjunto de treinamento

(BREIMAN *et al.*, 2017). RF's são baseadas em árvores e seguem regras específicas para crescimento da árvore, além de ser robusta para *overfitting* e estáveis considerando a presença de *outliers*. Utilizam índice gini como uma medida de seleção de atributo, o qual mede a impureza de um atributo em relação à classe (BREIMAN *et al.*, 2017).

- Naive Bayes: O classificador Naive Bayes (NB) é um algoritmo probabilístico, baseado no teorema de Bayes, capaz de classificar cenários multi-classes (GRANIK; MESYURA, 2017). Esse classificador assume que todos os atributos são independentes uns dos outros. NB são muito utilizadas para classificação de texto (LEWIS; GALE, 1994).
- Multi-layer Perceptron: Algoritmos de *Multi-layer perceptron* (MLP) pertencem ao grupo das redes neurais artificiais (RNA). Estas possuem camadas de entrada, saída e camadas ocultas. O MLP é treinado pelo algoritmo de retro-propagação onde os pesos conectando as camadas são atualizadas de forma iterativa. Uma vez treinada, a rede pode prever usando novos dados. São muito versáteis para classificação e regressão (RAVI; PRADEEPKUMAR; DEB, 2017).

2.8 MEDIDAS DE AVALIAÇÃO DE DESEMPENHO

Para se avaliar modelos de classificação, deve-se levar em conta os resultados preditos em contrapartida dos resultados reais daquilo que se está investigando (SANTOS, 2012). Essa avaliação se dá pelas métricas de avaliação adotadas, de acordo com o contexto. Nesse trabalho serão utilizados as seguintes métricas:

- Matriz de confusão: é uma matriz que aponta o número de falsos positivos, falso negativos, verdadeiros positivos e verdadeiros negativos, como mostrado na figura 14. A partir dela pode se chegar a outras métricas de avaliação de desempenho, como precisão e acurácia.

Figura 14 – Exemplo de matriz de confusão

		Classes verdadeiras	
		Positivo	Negativo
Classes preditas	Positivo	VP	FP
	Negativo	FN	VN

Fonte: O Autor (2021)

- Precisão: dentre as classificações positivas, qual a quantidade está correta.

$$precisao = \frac{VP}{VP + FP} \quad (2.11)$$

- Acurácia: Mostra quantas classificações corretas o modelo alcançou.

$$acuracia = \frac{VP + VN}{VP + FP + VN + FN} \quad (2.12)$$

- Revocação ou *recall*: dentre todas as situações positivas, quantas são de fato corretas.

$$revogacao = \frac{VP}{VP + FN} \quad (2.13)$$

- Score F1: trata-se da média harmônica entre precisão e revocação.

$$scoref1 = 2 * \frac{precisao * revogacao}{precisao + revogacao} \quad (2.14)$$

onde:

- VP = verdadeiro positivo
- FP = falso positivo
- VN = verdadeiro negativo
- FN = falso negativo

2.9 ANÁLISE ESTATÍSTICA DOS RESULTADOS

O teste de Friedman é um teste não-paramétrico utilizado como uma alternativa ao teste ANOVA regular, quando o presuposto de normalidade não pode ser garantido, ou quando as variações entre os fatores são diferentes ou as amostras são dependentes entre si (DEMŠAR, 2006). Além do teste de Friedman, outro teste chamado de teste de Nemenyi que mostra variações em pares pode ser utilizado para detectar diferença estatística. Esse teste realiza comparação em pares e assim verificar os fatores que se diferenciam entre si (POHLERT, 2014), (DEMŠAR, 2006).

3 MATERIAL E MÉTODOS

3.1 AMBIENTE E CONFIGURAÇÃO

Para o desenvolvimento dos algoritmos utilizados no processo de extração de características e análise de textura utilizou-se o ambiente Google Colab. Para implementação utilizou-se a linguagem Python 3.6, além da biblioteca multiplataforma de visão computacional OpenCV.

Diversas bibliotecas específicas para manipulação de imagem, operações matemáticas e para processamento de imagem e extração de características foram utilizadas, como a *Matplotlib*, que é usada para criação de gráficos, *Pandas* para análise e manipulação de dados, *Numpy* para suporte de *arrays* e matrizes multidimensionais, *scikit-image* para segmentação, transformações geométricas, manipulação do espaço de cores, análise, filtragem e morfologia. Utilizou-se, também, a *TensorFlow*, para aprendizado de máquina.

A biblioteca *scikit-learn*, uma biblioteca de aprendizado de máquina e de código aberto, foi utilizada para classificação, apresentação de métricas e resultados.

Os experimentos computacionais de aprendizado de máquina foram executada em um *cluster* de computadores de alto desempenho (LCAD), disponível para comunidade acadêmica da Universidade Estadual de Ponta Grossa (UEPG) e que conta com quatro servidores para processamento. Cada servidor conta com 48 processadores Intel Xeon 2.30 Ghz e 64 GB de memória RAM, com sistema operacional Linux Centos, versão 18.04.

3.2 BASE DE IMAGENS

Para a realização dos experimentos de aprendizado de máquina, imagens de agregados do tipo de granito e basalto foram adotadas. Foram compostas 3 bases de dados, sendo uma composta apenas de agregados de basalto (subseção 3.2.1), uma composta de agregados de granito (subseção 3.2.2) e uma terceira base, composta pela união das duas primeiras bases (subseção 3.2.3).

3.2.1 Basalto

O trabalho de Gouveia (2006) apresenta uma base de imagens de basalto em formato BMP, que é uma abreviação para *Bitmap* (mapa de bits), que passou pelas etapas de classificação quanto a alteração e que tem como resultado classes com três graus de alteração. Essas classes foram rotuladas como pouco alterado, alteração média, muito alterado e não-alterado, por especialistas na área.

A autora chegou nesse resultado depois de executar o teste de abrasão de Los Angeles, onde é possível determinar se o material é adequado para obras de engenharia civil, segundo normas próprias da área. A base contém 453 amostras coletadas em diferentes pedreiras brasileiras e foi dividida em quatro grupos como mostrado na tabela 3, de acordo com o grau de alteração:


Tabela 3 – Características e rótulos do basalto

Classe / Rótulo	Características	Abrasão Los Angeles (%)	Faixa (%)	Quantidade de imagens
0	Sem alteração	0	0	251
1	Pouco alterado	27	Abaixo de 30	51
2	Alteração média	36	Entre 30 e 40	100
3	Muito alterado	43	Acima de 40	51

Fonte: Adaptado de Gouveia (2006)

A figura 15 mostra 4 imagens de basalto com seus respectivos rótulos (classes).

Figura 15 – Imagens de agregados e seus rótulos



Fonte: O Autor (2021)

3.2.2 Granito

A base de granito contém 161 imagens em formato BMP, rotuladas em duas classes. Nessa base, o resultado de Abrasão de Los Angeles apontou uma classe não alterada com 53 amostras e outra classe muito alterada com 108 amostras. A tabela 4 traz os rótulos atribuídos para as amostras dessa base.


Tabela 4 – Características e rótulos granito

Classe	Características	Abrasão Los Angeles (%)	Faixa (%)	Quantidade de imagens
0	Sem alteração	0	0	53
3	Muito alterado	43	Acima de 40	108

Fonte: Adaptado de Gouveia (2006)

O granito, quando alterado, apresenta cores em tom de laranja e vermelho. A diferença entre as duas classes são melhor verificadas na figura 16 .

Figura 16 – Imagens de agregados e seus rótulos



Fonte: O Autor (2021)

A partir dessas bases de imagens e com os rótulos de cada classe definidos, foi possível trabalhar com as imagens a fim de identificar, em uma primeira análise, as características básicas das imagens, como histograma RGB, dimensões de altura e largura e a presença de ruídos, como o fundo da imagem (fundo escuro), e pequenas partículas de agregados presentes ao redor do agregado principal. A partir dessas informações foram definidos as próximas etapas, descritas na sequência.

3.2.3 Base Composta

Além da classificação da base de basalto e da base de granito, separadamente, optou-se por testar a classificação das bases unidas, ou seja, basalto e granito como uma base única. Para isso, as amostras rotuladas de 0 e 3 do granito foram adicionadas nas pastas 0 e 3 da base de basalto, criando assim uma nova base de imagens para então extrair as características e posteriormente classificar. O objetivo é verificar se os classificadores são capazes de separar diferentes tipos de agregados baseados no grau de alteração.

3.3 CARACTERÍSTICAS DAS IMAGENS E ELIMINAÇÃO DE RUÍDO


Os agregados disponíveis nas base de imagens contêm formato irregular com diversas faces, seu tamanho varia de uma amostra para outra. Em relação à textura, pode-se perceber uma semelhança entre os elementos da mesma classe (seja alterado ou não alterado).

Considerando que a textura dos agregados segue um padrão sem mudanças significativas de orientação, coloração, ou formato da textura e que o fundo deverá ser desconsiderado por não ser objeto do presente estudo, optou-se por considerar apenas uma parte de cada imagem, de mesmo tamanho para se extrair as características de textura.

A utilização da imagem do agregado por completo poderia ser utilizada, desde que fosse possível desconsiderar o fundo (escuro). Para que seja possível retirar o fundo existem técnicas como limiarização ou *thresholding*, que transforma uma imagem alterando o valor do pixel para um valor acima ou abaixo de um valor específico.

Para a análise de textura que utiliza o histograma RGB, essa técnica resolve o problema do ruído através da comparação da imagem original e da imagem limiarizada, conforme mostrado na figura 17.

Figura 17 – Imagem original (esquerda) e imagem limiarizada (direita)



Fonte: O Autor (2021)

Essa estratégia pode ser estendida para a etapa da análise de textura com LBP e LBPU, onde a análise também ocorre pixel a pixel, e pode-se utilizar comparações entre a imagem original e outra auxiliar, que excluem os ruídos dos cálculos para gerar a nova imagem ou o histograma desejado. Para os descritores, RGB, LBP, LBPU, entropia e escala de cinza essa abordagem foi realizada. E para esse grupo de dados foi dado o nome de Grupo B.

Na abordagem de extração de características das imagens onde utiliza-se a matriz de co-ocorrência, essa técnica de limiarização não pode ser empregada pelo fato de que o cálculo nessa etapa é realizado com a entrada da imagem completa (matriz), que então calcula as ocorrências de cada pixel gerando uma matriz e retorna o valor para cada descritor conforme os parâmetros de entrada (imagem, ângulo e distância), logo não há como excluir os ruídos.

Para resolver esse problema, uma alternativa seria utilizar as bases de imagem sem ruídos. Assim sendo, optou-se, então, por tratar as bases de imagens e utilizar apenas a parte da imagem que contém informações do agregado.

Através de comandos da biblioteca *Opencv* foi recortado parte da imagem, indicando altura e largura de início e fim como dados de entrada e assim gerar uma nova imagem, conforme mostra a figura 18. Feito isso, duas novas bases de imagens sem ruído considerável foram criadas. Esse novo grupo de dados recebeu o nome de Grupo A.



Figura 18 – Imagem original (I) e imagem recortada (II)



Fonte: O Autor (2021)

A tabela 5 mostra a diferença entre grupo A e grupo B, processo que tem por objetivo testar as imagens com duas abordagens diferentes.


Tabela 5 – Grupos de imagens

Grupo	Características	Exemplo de imagem
A	Imagem recortada	
B	Imagem original, excluindo fundo	

Fonte: O Autor (2021)

Após recortar todas as imagens, em ambas as bases, aplicou-se a técnica de *Data augmentation*. Nessa etapa optou-se por alterar a luminosidade de cada imagem variando de 10 em 10 a porcentagem de luminosidade no intervalo de 40% e 120%, a partir da imagem original, gerando outras nove imagens para cada amostra da base. A figura 19 mostra o exemplo com 10 imagens geradas para o basalto e 10 imagens geradas para o granito.

Figura 19 – Aplicação de Data Augmentation (DA)



Fonte: O Autor (2021)

O número de amostras final foi de 4530 para a base de basalto e de 1771 para a base de granito. Para realizar essa etapa foi utilizada a função *ImageDataGenerator* da biblioteca *Tensorflow* para gerar as imagens.

A configuração final das bases de dados adotadas está ilustrada na Tabela 6.

Tabela 6 – Configuração final das bases

Tipo	Classes	Total de imagens
Basalto	0, 1, 2, 3	4530
Granito	0, 3	1770
Basalto + granito	0, 1, 2, 3	6300

Fonte: O Autor (2021)

3.4 PRÉ-PROCESSAMENTO

Para que houvesse um padrão nas características das imagens, foi executado, para cada imagem, o redimensionamento de suas dimensões, através da função *resize* do Opencv, além da conversão do padrão de cores padrão BGR para o RGB, que é o padrão utilizado pelo LBP e LBPU. Ambos os comandos são mostrados abaixo no código 3.1:

Código 3.1 – Código de alteração tamanho da imagem e conversão RGB

```

1 # Concatena o endereço, o nome do arquivo e a classe.
2 name = str(path)+str(class_names[classe])+str('/')+str(classes_files[i])
3 # Armazena em imagem, o nome completo do arquivo da amostra
4 imagem = cv2.imread(name)
5 # Realiza o redimensionamento da imagem
6 imagem = cv2.resize(imagem, (64, 64))
7 # Converte para o formato RGB
8 imagem = cv2.cvtColor(imagem, cv2.COLOR_BGR2RGB)

```

3.5 EXTRAÇÃO DE CARACTERÍSTICAS

O processo de extração de características coleta as informações dos algoritmos de análise de textura da imagem. São essas informações que serão usadas para classificar as amostras, objetivo dessa pesquisa. Essa etapa é organizada em cinco funções principais:

- Cálculo da frequência de histograma para cada canal de cor e tons de cinza;
- Cálculo da entropia dos canais RGB;
- Geração do histograma LBP;
- Geração do histograma LBPU;
- Extração de informações a partir da GLCM.

No descritor de cálculo de frequência de histograma para cada canal de cor, calculou-se a quantidade de vezes que uma intensidade de cor aparece na imagem e divide pelo valor referente ao tamanho dela (altura x largura). Os resultados dessa etapa são três vetores de 256 posições que representam os três canais de cores da imagem, totalizando 768 atributos. Para o caso da imagem em tons de cinza, outro vetor com 256 posições foi criado.

O cálculo da entropia foi aplicado para cada canal de cor, utilizando a função entropia de Shannon, que está disponível no Opencv, a qual retorna um número por canal das imagens das bases.

O próximo descritor gera uma imagem LBP e LBPU a partir da imagem original e então cria-se o histograma. O cálculo é baseado em quatro informações principais que são a imagem, o método (padrão ou uniforme), o raio e a quantidade de pontos que serão considerados ao redor do pixel central. O raio considerado foi o valor 1 e o número de pontos foram definidos como 8. O mesmo processo acontece com a imagem LBPU.

Diferente do cálculo da frequência do histograma RGB, os descritores LBP e LBPU, por padrão, utilizam a imagem em tons de cinza para calcular os seus respectivos histogramas. Para que isso seja realizado, deve-se alterar a imagem para tons de cinza e assim passá-la para o algoritmo. Optou-se nesse trabalho, realizar a modificação das informações de cada canal para que a imagem passada levasse as informações das cores originais, levando-se em conta que a imagem cinza é o resultado do cálculo da média das informações dos canais RGB.

O código 3.2 foi utilizado para alterar a informações dos canais. Gerou-se então uma imagem auxiliar onde cada canal R, G e B receberam a informação do canal R. Essa imagem auxiliar será então convertida para uma imagem em tons de cinza. Dessa forma as informações originais de cor serão usadas no cálculo LBP e LBPU.

Código 3.2 – Código de alteração de informação de canais de cor

```

1 for y in range(0, altura): # percorre as linhas da imagem
2     linha_r = []
3     for x in range(0, largura): # percorre as colunas da imagem
4         vermelho = imagem_lbp.item(y, x, 0) # pega a informacao do canal R
5         verde = imagem_lbp.item(y, x, 1) # captura a informacao do canal G
6         azul = imagem_lbp.item(y, x, 2) # captura a informacao do canal B
7         linha_r.append(vermelho) # concatena as informacoes do canal R
8     matriz_r.append(linha_r) # cria a imagem para calculo LBP

```

O último descritor calcula seis atributos da imagem baseado em matriz de co-ocorrência. O atributos foram homogeneidade, energia, contraste, correlação, dissimilaridade e entropia. O cálculo da imagem GLCM exige que os parâmetros de ângulo e distância sejam indicados juntamente com a imagem. Para esse cálculo foram considerados os valores de 1, 2 e 3 para distância e 0°, 45°, 90°, 135° para os ângulos.

Todas as informações coletadas com os descritores, formaram um vetor de atributos para cada imagem da base, que foram então organizadas com o método *ravel* do *numpy* antes de serem exportadas para um arquivo com extensão CSV. Para a exportação utilizou-se a biblioteca Pandas para manipulação e análise de dados. Os dados foram exportados para dois arquivos chamados de X, que contém os dados extraídos e concatenados, e Y, que contém as classes ou rótulos de cada imagem.

3.6 DELINEAMENTO EXPERIMENTAL

Em cada experimento foi separado um conjunto de dados o qual seria submetido à classificação e assim medir o desempenho dos classificadores. Para cada conjunto de dados foram atribuídos nomes para cada experimento de C1 até C20, totalizando 20 classificações para cada algoritmo de classificação. Os seguintes experimentos foram executados:

- No experimento C1, o histograma de tons de cinza foi selecionado e submetido a classificação isoladamente;
- No segundo experimento, C2, apenas os dados de frequência do canal R foram utilizados;
- No experimento C3, a frequência do canal G e no experimento C4, os dados de frequência do canal B;
- No experimento C5 apenas os dados do descritor LBP foram extraídos;
- O próximo experimento, C6, os dados do descritor LBPU foram testados isoladamente;
- Em C7, foi a vez das informações obtidas com o descritor GLCM;
- Os dados das frequências R, G e B foram combinados no experimento C8;
- No experimento C9 foram combinados os dados de LBP e GLCM;
- No experimento C10, foram testadas juntas as informações de LBPU e GLCM;
- Em C11, foram testadas as informações de frequência dos canais R, G e B junto com o descritor LBP;
- Seguindo para C12, as frequências dos canais R, G e B agora foram combinadas com LBPU;
- Na sequência, em C13, foram combinados os dados de frequência dos canais R, G e B com as informações obtidas do descritor GLCM;
- Os dados de frequência da imagem em tons de cinza foram combinadas com LBP no experimento C14. Esses mesmos dados foram combinados com LBPU em C15;
- Para a sequência C16 foi a vez de combinar GLCM com os dados de frequência da imagem em tons de cinza;

- O descritor LBP foi combinado com a entropia do canal R no experimento C17, com a entropia do canal G, no experimento C18 e com a entropia do canal B em C19;
- Por fim, em C20 uniu-se a entropia dos canais R, G e B.

Todas os experimentos foram resumidos no esquema mostrado na tabela 7 de acordo com cada abordagem definida.

Tabela 7 – Descritores utilizados para classificação

Experimento	Cinza	Freq. R	Freq. G	Freq. B	LBP	LBPU	GLCM	Ent. R	Ent. G	Ent. B
C1	X									
C2		X								
C3			X							
C4				X						
C5					X					
C6						X				
C7							X			
C8		X	X	X						
C9					X		X			
C10						X	X			
C11		X	X	X	X					
C12		X	X	X		X				
C13		X	X	X			X			
C14	X				X					
C15	X					X				
C16	X						X			
C17					X			X		
C18					X				X	
C19					X					X
C20								X	X	X

Fonte: O Autor (2021)

3.7 APRENDIZADO SUPERVISIONADO DE MÁQUINA

A tarefa de classificação foi realizada aplicando a configuração padrão de cada classificador, conforme documentação oficial. Porém, no caso dos classificadores KNN e MLP, alguns parâmetros foram alterados. Nos casos onde houve alteração, os parâmetros alterados foram mostrados. Os classificadores selecionados são: KNN, *Naive Bayes*, *Árvore de decisão*, MLP e RF.

3.7.1 KNN

O primeiro classificador utilizado foi o KNN. Para esse estudo optou-se por atribuir o número 3 para os vizinhos junto com a distância euclidiana.

Parâmetros: `n_neighbors=3 ; metric='euclidean'`

3.7.2 Naive Bayes

As métricas padrão desse classificador foram adotadas para todas as etapas.
Parâmetros: `priors = None`, `var_smoothing=1e-09`

3.7.3 Decision Tree

As configurações padrão desse classificador foram adotadas para classificação, como o Índice *Gini*, e;

Parâmetro: `splitter = best`

3.7.4 Multi-layer Perceptron

No classificador Multi-Layer perceptron (MLP) foi aplicada uma modificação no parâmetro `max_iter`, aumentando o número de 200 para 2000.

Parâmetro: `max_iter=2000`

3.7.5 Random Forest

Na classificação usando o Random Forest, atribuiu-se o valor 2 para o `max_depth`.

Parâmetro: `max_depth = 2`

3.8 OBTENÇÃO DOS RESULTADOS

Para cada experimento de classificação foram utilizados os 5 classificadores. Esse processo gerou um total de 100 tarefas de classificação, sendo 20 para cada classificador. Para facilitar e automatizar esse processo foram desenvolvidos *scripts* em *shell script* (linux) onde tanto as tarefas de extração de características quanto as classificações pudessem ocorrer sequencialmente (código 3.3).

Código 3.3 – Script de extração de características

```

1 #!/bin/bash
2 scripts = "C1 C2 C3 C4 ... C19 C20" # define os scripts python
3
4 for scr in ${scripts}; do # percorre os scripts
5     mkdir $scr # cria a pasta
6     python3 $scr.py # executa código python para extrair as características
7 done

```

No processo de extração de características, o algoritmo percorreu as bases e os cálculos foram executados baseados nos descritores e no fim foram gravados os

dados em arquivos com extensão CSV, em pastas identificadas para cada experimento sequencialmente de C1 a C20.

Já no processo de classificação, outro *script* (código 3.4) foi responsável por chamar cada um dos cinco classificadores que por sua vez testavam cada conjunto de dados. Assim que o classificador termina sua tarefa, os resultados da classificação serão salvos em arquivos de texto contendo as informações de classificação como nome do classificador, média, variância, variância em cada *fold*, acurácia, matriz de confusão e relatório com as informações de *f1-score*, precisão e revocação.

Código 3.4 – Script de classificação

```

1 #!/bin/bash
2 classificadores = "KNN DT NB MLP RF" # define os classificadores
3 pastas = "C1 C2 C3 C4 ... C19 C20" # define os scripts python
4
5 for classif in ${classificadores}; do # percorre os classificadores
6     for dir in ${pastas}; do # percorre as pastas com as características
7         # executa o classificador e grava resultados no arquivo txt
8         python3 $dir'_'$classif'.py' > $dir'_'$classif'_result.txt'
9     done
10 done

```

Concluída a tarefa de classificação, os dados foram tabulados para então serem analisados pelas ferramentas estatísticas (seção 3.9).

3.9 ANÁLISE ESTATÍSTICA DOS RESULTADOS

Para realizar a análise estatística foi utilizado o teste de Friedman para verificar se os dados apresentam ou não semelhança estatística.

O teste de Friedman foi realizado nos dados da variância dos 10 *folds* que o classificador calculou. Como foram realizadas 20 etapas de classificação, o teste de Friedman foi aplicado sobre 20 grupos de 10 elementos cada. Para verificar quais grupos diferem entre si foi utilizado o teste de *post hoc Nemenyi*, que comparou os grupos em pares. Em ambos os testes, adotou-se um nível de significância de 95%.

4 RESULTADOS

Os resultados serão divididos em dois grupos chamados de grupo A e grupo B. No grupo A, serão apresentados os resultados utilizando a base de dados com amostras dos agregados. Já no grupo B, os resultados apresentados são baseados no agregado completo excluindo o fundo escuro, conforme descrito na seção 3.3.

Após as etapas de classificação e análise estatística, os resultados serão apresentados primeiro para a base de basalto, seguido da base de granito e, por fim, os resultados da base unificada que traz o basalto e o granito. Optou-se por separar os resultados por classificador, começando com o KNN, seguido de NB, MLP, DT e por fim RF. Essa mesma sequência será utilizada para o grupo A e B.


4.1 GRUPO A

4.1.1 Acurácia do Basalto - KNN

Após a análise estatística (tabela A1), observou-se que os experimentos C1, C2, C3 e C4 não apresentaram diferença estatística significativa em comparação com as etapas C8 e C20.

As demais etapas apresentaram diferenças significativas entre si, segundo o teste de Nemenyi. As acurácias para cada experimento estão demonstradas na figura 20.

Figura 20 – Gráfico das acurácias do basalto - KNN



Fonte: O Autor (2021)

O classificador obteve 100% de acerto para as etapas C5 a C7, C9 a C19. Para o experimento C1, a acurácia foi de 0,54, em C2 o resultado foi de 0,49. Para os experimento C3 e C4 o KNN obteve 0,51 e 0,54, respectivamente.

O resultado apresentado para o experimento C8 foi de 0,66 e, por fim, em C20 a acurácia foi de 0,72. Os resultados dos experimentos são mostrados na tabela 8 que

também contém das informações de desvio padrão e variância.

Tabela 8 – Resultados de classificação KNN do basalto

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,54	0,02	0,0
C2	0,49	0,02	0,0
C3	0,51	0,01	0,0
C4	0,53	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,66	0,02	0,0
C9	1,00	0,00	0,0
C10	1,00	0,00	0,0
C11	1,00	0,00	0,0
C12	1,00	0,00	0,0
C13	1,00	0,00	0,0
C14	1,00	0,00	0,0
C15	1,00	0,00	0,0
C16	1,00	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,72	0,02	0,0

Fonte: O Autor (2021)

4.1.2 Acurácia do Basalto - Naive Bayes

A análise estatística (tabela A2) dos dados do basalto, quando classificados pelo *Naive Bayes*, apontaram que os experimentos C5, C6, C9, C11 a C13 e C17 a C19 possuem diferença estatística em relação aos experimentos C1, C2 e C3.

O experimento C4 possui diferença estatística em relação aos experimentos C5, C9, C17, C18 e C19.


Para o experimento C5 e C6, notou-se diferença estatística entre C8 e C20. O teste de Nemenyi apresentou diferença estatística entre o experimento C7 e C9, C17 e C18. Os demais experimentos não apresentaram diferenças estatísticas.

Em relação às acurácias obtidas pelo classificador, o experimento C1 obteve 0,41, o C2 apontou 0,32 e 0,34 para o C3. O resultado de C4 foi de 0,56, e de 0,66 no experimento C5.

O experimento C6 apresentou 0,64 de acurácia, seguido de 0,58 no experimento C7. Em C8, o *Naive Bayes* apontou 0,50 de acurácia, 0,65 em C9 e 0,61 nos experimentos C10, C11 e C13. A acurácia de 0,62 foi apontada para C12.

Os experimentos C14, C15 e C16 apresentaram 0,59 de acurácia. Já em C17 e C19, a acurácia foi de 0,67. Por fim, tem-se 0,68 para C18 e 0,52 para C20. Os resultados estão disponíveis na tabela 9. O desempenho do NB está demonstrado na figura 21.

Figura 21 – Gráfico das acurácias do basalto - NB



Fonte: O Autor (2021)

Tabela 9 – Resultados de classificação Naive Bayes do basalto

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,41	0,01	0,0
C2	0,32	0,02	0,0
C3	0,34	0,02	0,0
C4	0,56	0,03	0,0
C5	0,66	0,02	0,0
C6	0,64	0,02	0,0
C7	0,58	0,02	0,0
C8	0,50	0,02	0,0
C9	0,65	0,02	0,0
C10	0,61	0,02	0,0
C11	0,61	0,02	0,0
C12	0,62	0,02	0,0
C13	0,61	0,02	0,0
C14	0,59	0,02	0,0
C15	0,59	0,02	0,0
C16	0,59	0,02	0,0
C17	0,67	0,02	0,0
C18	0,68	0,02	0,0
C19	0,67	0,02	0,0
C20	0,52	0,02	0,0

Fonte: O Autor (2021)

4.1.3 Acurácia do Basalto - DT


Observando a análise estatística (tabela A3) dos experimentos C4, C5, C6, C9, C10, C11, C14 percebe-se diferenças estatísticas entre si. Os experimentos C5 e C6 apresentam diferenças com o grupo C20. Verificou-se diferenças entre os grupos C8, C9, C10, C11 e C14. Em relação ao experimento C20, há diferenças entre C9, C10, C11, C14 e C17. Para os demais grupos não existe diferença significativa, quando comparados aos pares.

Os resultados de acurácia (figura 22) para o classificador de árvore de decisão mostraram que, para o experimento C1, o valor foi de 0,64, seguido de 0,61 para C2. Já para C3, obteve-se 0,55 e 0,73 para C4.

A acurácia de 0,97 foi obtida para os experimentos C5, C6, C9, C10, C11 e C17. Os experimentos C7, C12 e C15 receberam 0,95 de acurácia. Em C8, o resultado foi de

0,78. Observou-se o resultado de 0,94 para os experimentos C13 e C16. O classificador apontou 0,96 em C14, C18 e C19. Por fim, 0,72 foi o resultado para C20.

Figura 22 – Gráfico das acurácias do basalto - DT



Fonte: O Autor (2021)

Para esses dados, a tabela 10 traz, ainda, desvio padrão e variância.

Tabela 10 – Resultados de classificação árvore de decisão do basalto

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,64	0,03	0,0
C2	0,61	0,02	0,0
C3	0,55	0,02	0,0
C4	0,73	0,02	0,0
C5	0,97	0,01	0,0
C6	0,97	0,01	0,0
C7	0,95	0,01	0,0
C8	0,74	0,02	0,0
C9	0,97	0,01	0,0
C10	0,97	0,01	0,0
C11	0,97	0,01	0,0
C12	0,95	0,02	0,0
C13	0,94	0,01	0,0
C14	0,96	0,01	0,0
C15	0,95	0,01	0,0
C16	0,94	0,02	0,0
C17	0,97	0,01	0,0
C18	0,96	0,01	0,0
C19	0,96	0,01	0,0
C20	0,72	0,02	0,0

Fonte: O Autor (2021)

4.1.4 Acurácia do Basalto - MLP

Para esse conjunto de dados, o teste de Nemenyi (tabela A4) trouxe as seguintes informações: Os experimentos C1, C8 a C10 não apresentaram diferenças estatísticas com nenhum outro par.

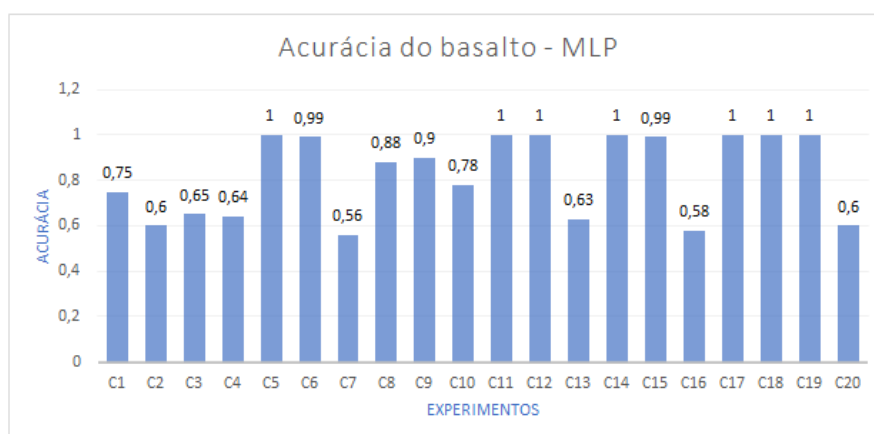
Para os experimentos C2, C3 e C4, o teste de Nemenyi constatou que há diferença estatística com os grupos C11, C12, C14, C15, C17, C8 e C19.

Há diferença estatística entre os experimentos C5, C7, C13, C16 e C20. Já em C6 observa-se diferenças com C16 e C20. O conjunto de dados C7 mostrou-se diferente, estatisticamente, em relação aos grupos C11, C12, C14, C15 e C17 a C19.

Os experimentos C11 e C12 se diferem de C13, C16 e C20, segundo o mesmo teste. Já o experimento C16 não apresenta diferença estatística apenas com C20. Os experimentos C17, C18 e C19 apresentam diferença estatísticas com C20. Os demais experimentos não apresentaram diferenças estatística.

O resultado de acurácia (figura 23), quando o basalto foi testado pelo MLP, para o experimento C1 foi de 0,75. Para os experimentos C2 e C20, o valor foi de 0,60 de acurácia. No experimento C3 o valor obtido foi de 0,65, seguido de 0,64 para C4. Já para os experimentos C5, C11, C12, C14, C17, C18 e C19 o classificador atingiu 100% de acerto.

Figura 23 – Gráfico das acurácias do basalto - MLP



Fonte: O Autor (2021)

O mesmo valor de 0,99 de acurácia foi atribuído aos experimentos C6 e 15. O experimento C7 apontou 0,56 e 0,88 para o experimento C8. Na sequência, o experimento C9 recebeu o valor de 0,90 de acurácia.

A classificação com o MLP mostrou, ainda, que o resultado de C10 apontou 0,78 de acurácia. Os experimentos C13, C15 e C16 obtiveram 0,63, 0,99 e 0,58 de acurácia, respectivamente. Os dados de acurácia, desvio padrão e variância são mostrados na tabela 11.

Tabela 11 – Resultados de classificação MLP do basalto

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,75	0,02	0,0
C2	0,60	0,03	0,0
C3	0,65	0,02	0,0
C4	0,64	0,02	0,0
C5	1,00	0,00	0,0
C6	0,99	0,01	0,0
C7	0,56	0,09	0,1
C8	0,88	0,01	0,0
C9	0,90	0,06	0,0
C10	0,78	0,04	0,0
C11	1,00	0,02	0,0
C12	1,00	0,02	0,0
C13	0,63	0,07	0,1
C14	1,00	0,00	0,0
C15	0,99	0,01	0,0
C16	0,58	0,10	0,1
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,60	0,01	0,0

Fonte: O Autor (2021)


4.1.5 Acurácia do Basalto - RF

Os dados referentes à análise estatística do basalto (tabela A5), mostraram o seguinte resultado: Os experimentos C1, C2, C3, C4 apresentam diferenças estatísticas com os experimentos C5, C6, C7, C9, C10, C11, C14, C17, C18 e C19. Para os dados de C2 e C3, há diferença estatística em relação a C15.

Os experimentos C5, C6, C7, C9, C10, C11, C14, C17, C18 e C19 se diferem do experimento C20, segundo o teste de Nemenyi. Para os demais experimentos, não há diferença estatística.

O classificador *Random Forest* testou os dados das imagens de basalto, como mostra a figura 24, trazendo os seguintes resultados: acurácia de 0,76 para o experimento C1 e C20, o valor de 0,65 para o experimento C2. O teste mostrou valores de acurácia de 0,67 e 0,81, para C3 e C4, respectivamente.

Figura 24 – Gráfico das acurácias do basalto - RF



Fonte: O Autor (2021)

Ocorreu 100% de acerto para os experimentos C5, C6, C7, C9, C10, C11, C14, C17, C18 e C19. O classificador apontou uma acurácia de 0,85 para o experimento C8.

Nos experimentos C12 e C13, o valor obtido foi de 0,98, e para os experimentos C14 e C15 a resposta do RF foi de 0,99. Por fim, o experimento C20 recebeu o valor de 0,76 de acurácia.

Tabela 12 – Resultados de classificação *Random Forest* do basalto

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,76	0,02	0,0
C2	0,65	0,01	0,0
C3	0,67	0,02	0,0
C4	0,81	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,85	0,01	0,0
C9	1,00	0,00	0,0
C10	1,00	0,00	0,0
C11	1,00	0,02	0,0
C12	0,98	0,01	0,0
C13	0,98	0,01	0,0
C14	1,00	0,00	0,0
C15	0,99	0,00	0,0
C16	0,99	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,76	0,02	0,0

Fonte: O Autor (2021)

4.1.6 Acurácia do Granito - KNN

Os experimentos C1, C3 e C4 apresentaram diferença estatística em relação aos experimentos C5, C6, C9, C10, C11, C12, C13, C14, C15, C17, C18 e C19. O experimento C20 apresentou diferença estatística em relação aos experimentos C5, C6, C9, C10, C11, C12, C13, C14, C15, C17, C18, C19.


Para os demais experimentos, não ocorreram diferenças estatísticas, segundo teste de Nemenyi (tabela A6).

Seguindo nos experimentos, o granito foi testado com o classificador KNN. A resposta do classificador apontou que no experimento C1, o valor obtido foi de 0,83, seguido de 0,90 para C2. Nos experimentos C3 e C20, o valor de acurácia foi de 0,81.

A acurácia de C4 ficou em 0,78. O classificador conseguiu acurácia de 100% para os experimentos C5, C6, C7, C9, o mesmo resultado para os experimentos de C10 até C19. O KNN apontou, ainda, o valor de 0,99 para o experimento C8. Todos os valores de acurácia estão representados no gráfico da figura 25.

Os dados de acurácia, desvio padrão e variância para essa classificação são mostrados na tabela 13.

Figura 25 – Gráfico das acurácias do granito - KNN



Fonte: O Autor (2021)

Tabela 13 – Resultados de classificação KNN do granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,83	0,02	0,0
C2	0,90	0,02	0,0
C3	0,81	0,02	0,0
C4	0,78	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,99	0,01	0,0
C9	1,00	0,00	0,0
C10	1,00	0,00	0,0
C11	1,00	0,00	0,0
C12	1,00	0,00	0,0
C13	1,00	0,00	0,0
C14	1,00	0,00	0,0
C15	1,00	0,00	0,0
C16	1,00	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,81	0,03	0,0

Fonte: O Autor (2021)

4.1.7 Acurácia do Granito - NB

O experimento C1 apresentou diferença estatística entre os experimentos C8, C11 e C12. Já no experimento C2, houve diferença entre C7, C10, C16 e C20.

O teste de Nemenyi (A7) apontou que C3 e C4 apresentam diferença estatística entre C8, C11 e C12.

O experimento C5 se difere em relação aos experimentos C7, C10, C16 e C20, enquanto C6 é diferente estatisticamente apenas de C11. Da mesma forma, C7 é diferente de C11, C12, C14, C17, C18 e C19.

O teste apontou, ainda, que C8 se difere de C9, C10, C13, C15, C16 e C20. Já C9 apresenta diferença estatística apenas com C11. O experimento C10 é diferente de C11, C12, C17, C18, e C19. Em relação ao experimento C11, há diferença quando comparado a C13, C15, C16 e C20.


O experimento C12 se difere estatisticamente de C13, C15, C16 e C20. Os experimentos C13 e C15 não apresentaram diferenças com nenhum experimento.

O teste estatístico mostrou diferença entre C14 e C20. Em relação ao experimento C16, existe diferença com C17, C18, C19. Por fim, foi notado diferença entre C17 e C20, e, ainda, entre C18 e C20.

No processo de classificação, o algoritmo *Naive Bayes* apresentou os seguintes resultados para o granito: acurácia de 0,76 para os experimentos C1 e C20. Os experimentos C2, C3 e C4 apontaram para acurácia de 0,65, 0,67 e 0,81, respectivamente.

O classificador mostrou os mesmos valores para os experimentos C5, C6, C7, C9, C10, C11, C14, C17, C18 e C19, alcançando 100% de acurácia. Já em C8, a resposta foi de 0,85, e para os experimentos C12 e C13 a acurácia foi de 0,98. Finalizando o teste com NB, o valor de 0,99 de acurácia foi atribuído para C15 e C16. Todos os valores obtidos pelo classificador NB estão representados no gráfico 26. O desempenho do *Naive Bayes* pode ser verificado na tabela 14.

Figura 26 – Gráfico das acurácias do granito - NB



Fonte: O Autor (2021)

Tabela 14 – Resultados de classificação Naive Bayes do granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,76	0,02	0,0
C2	0,65	0,01	0,0
C3	0,67	0,02	0,0
C4	0,81	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,85	0,01	0,0
C9	1,00	0,00	0,0
C10	1,00	0,00	0,0
C11	1,00	0,02	0,0
C12	0,98	0,01	0,0
C13	0,98	0,01	0,0
C14	1,00	0,00	0,0
C15	0,99	0,00	0,0
C16	0,99	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,76	0,02	0,0

Fonte: O Autor (2021)

4.1.8 Acurácia do Granito - DT

Ao realizar o teste estatístico de Nemenyi (tabela A8), no granito, foi observado o seguinte resultado: O experimento C1 apresenta diferença estatística em relação a C8, C9, C10, C11, C12 e C13. O experimento C2 se difere de C5, C8, C9, e C10. Há diferença estatística entre C3 e os experimentos C5, C6, C8, C9, C10, C11, C12, C13, C14.

O experimento C4 tem diferenças em comparação com C5, C6, C8, C9, C10, C11, C12, C13, C14 e C9. O teste de Nemenyi apontou diferença entre C5 e C20.


E em relação a C20, os experimentos C8, C9, C10, C11, C12 e C13 se diferenciam estatisticamente. Os demais experimentos não apresentam diferenças estatísticas.

O granito foi submetido ao teste de classificação através de árvore de decisão, onde os resultados foram os seguintes: C1 apresentou uma acurácia de 0,82, o valor de 0,89 foi atribuído a C2 e 0,79 para os experimentos C3 e C20.

O valor de 0,78 ficou para o C4. Os demais experimentos obtiveram resultados bem próximos, como 0,95 para C5 e C8, e uma acurácia de 0,94 para C6, C11, C12, C13 e C14. Os experimentos C7 e C19 apresentaram acurácia de 0,93 e o valor obtido por C9 e C10 foi de 0,96.

O classificador apontou o resultado de 0,91 para C15 e 0,92 para os experimentos C16, C17 e 18. Na figura 27, é possível verificar o gráfico das acurácias que o algoritmo determinou.

Figura 27 – Gráfico das acurácias do granito - DT



Fonte: O Autor (2021)

Tabela 15 – Resultados de classificação Arvore de decisão do granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,82	0,01	0,0
C2	0,89	0,02	0,0
C3	0,79	0,03	0,0
C4	0,78	0,03	0,0
C5	0,95	0,01	0,0
C6	0,94	0,01	0,0
C7	0,93	0,02	0,0
C8	0,95	0,01	0,0
C9	0,96	0,01	0,0
C10	0,96	0,02	0,0
C11	0,94	0,02	0,0
C12	0,94	0,01	0,0
C13	0,94	0,01	0,0
C14	0,94	0,02	0,0
C15	0,91	0,02	0,0
C16	0,92	0,02	0,0
C17	0,92	0,02	0,0
C18	0,92	0,02	0,0
C19	0,93	0,02	0,0
C20	0,79	0,02	0,0

Fonte: O Autor (2021)

A acurácia, o desvio padrão e a variância, são mostrados na tabela 15.

4.1.9 Acurácia do Granito - MLP

Em relação ao teste de Nemenyi para o granito (tabela A9), quando classificado pelo MLP, o resultado foi o seguinte: Os experimentos C1 e C3 apresentam diferenças estatísticas apenas com C11. Em relação ao experimento C4, há diferença em comparação com os experimentos C5, C6, C8, C11, C12, C14, C17, C18 e C19.

O teste revelou que C5 é diferente de C7, C10, C13, C16 e C20, estatisticamente. C6 apresenta diferenças em relação à C7, C10, C13 e C16. O experimento C7 apresenta diferença em relação à C8, C11, C12, C14, C15, C17, C18 e C19. Os dados classificados de C8 se diferem de C10, C13, C16 e C20.


Para C10, há diferença em relação a C11, C12, C14, C17, C18 e C19. Seguindo para os experimentos C11 e C12, existe diferença estatística em comparação a

C13, C16 e C20. O teste de Nemenyi mostra que são diferentes estatisticamente os experimentos C13, C14, C15, C17, C18 e C19. Percebe-se diferença entre C14 e os grupos C16 e C20.

O experimento C15 apresenta diferença estatística em comparação com C16. Já C16 tem diferenças entre C17, C18 e C19. Por fim, o teste mostrou que C17 e C19 são diferentes de C20.

O granito também foi submetido a avaliação do classificador MLP e os resultados, demonstrados na figura 28.

Figura 28 – Gráfico das acurácias do granito - MLP



Fonte: O Autor (2021)

Os resultados foram: uma acurácia de 0,76 para os experimentos C1 e C20. O valor de 0,65 em C2, 0,67 para C3 e 0,81 no experimento C4. A acurácia de 100% foi atribuída para os experimentos C5, C6, C7, C9, C10, C11, C14, C7, C18 e C19. Já para o experimento C8 o valor foi de 0,85 de acurácia. Obteve-se o valor de acurácia de 0,98 para C12 e C13. Os experimentos C15 e C16 alcançaram o valor de 0,99. O resultado de classificação do MLP para o granito está demonstrado na tabela 16.

Tabela 16 – Resultados de classificação MLP do granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,76	0,02	0,0
C2	0,65	0,01	0,0
C3	0,67	0,02	0,0
C4	0,81	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,85	0,01	0,0
C9	1,00	0,00	0,0
C10	1,00	0,00	0,0
C11	1,00	0,02	0,0
C12	0,98	0,01	0,0
C13	0,98	0,01	0,0
C14	1,00	0,00	0,0
C15	0,99	0,00	0,0
C16	0,99	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,76	0,02	0,0

Fonte: O Autor (2021)

4.1.10 Acurácia do Granito - RF

A análise estatística (tabela A10), mostrou que o experimento C1 se difere estatisticamente de C8, C11, C12 e C13. Os dados de C2 apresentam diferenças estatísticas com C3, C4, C5 e C6.

Os experimentos C2, C3, C4, C5 e C6 se diferem de C8, C11, C12, C13 e C16. Para os dados do experimento C8, há diferença estatística em relação a C18, C19 e C20.


O teste de Nemenyi mostrou que C11, C12, C13 são estatisticamente diferentes de C17, C18, C19 e C20. O experimento C16 é diferente de C19. Os demais experimentos não mostraram diferenças estatísticas quando comparadas aos pares.

O classificador *Random Forest*, quando testado com o granito, apontou os seguintes resultados: Experimentos C1, C18 e C20 obtiveram uma acurácia de 0,78. Em C2, a resposta foi de 0,84 e 0,77 para C3, C4 e C19.

A acurácia dos experimentos C5 e C6 foi de 0,76. Para os experimentos C7 e C10, o valor obtido foi de 0,81. Em C8, a acurácia foi de 0,91 e 0,80 para C9, C14 e C15.

Os experimentos C11, C12 e C13 receberam o mesmo valor de 0,92 de acurácia. O classificador obteve os resultados de 0,86 para C16, e 0,79 para C17.

Figura 29 – Gráfico das acurácias do granito - RF



Fonte: O Autor (2021)

Para essa classificação, além da acurácia, o desvio padrão e a variância para cada experimento estão apresentados na tabela 17.

A seguir será mostrado os resultados das classificações com a base composta, ainda com os dados do grupo A.

Tabela 17 – Resultados de classificação Random Forest do granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,78	0,03	0,0
C2	0,84	0,02	0,0
C3	0,77	0,03	0,0
C4	0,77	0,02	0,0
C5	0,76	0,02	0,0
C6	0,76	0,02	0,0
C7	0,81	0,03	0,0
C8	0,91	0,02	0,0
C9	0,80	0,03	0,0
C10	0,81	0,03	0,0
C11	0,92	0,02	0,0
C12	0,92	0,02	0,0
C13	0,92	0,02	0,0
C14	0,80	0,02	0,0
C15	0,80	0,03	0,0
C16	0,86	0,02	0,0
C17	0,79	0,02	0,0
C18	0,78	0,02	0,0
C19	0,77	0,02	0,0
C20	0,78	0,03	0,0

Fonte: O Autor (2021)

4.1.11 Acurácia do Basalto + Granito - KNN

O resultado da análise estatística revelou que os experimentos C1, C2, C3 e C4 apresentam diferenças estatísticas em relação aos experimentos C5, C6, C7, C9, C10, C11, C12, C13, C14, C15, C16, C17, C18 e C19.

Para todos os outros experimentos, não foram apontadas diferenças estatísticas, segundo o teste de Nemenyi (tabela A11).


Nesse experimento, as bases de imagens foram unificadas (basalto + Granito) e o classificador KNN testou as informações de textura. O resultado foi o seguinte: o experimento C1 obteve uma acurácia de 0,56, seguido de 0,57 para C2. Em C3 a acurácia foi de 0,52 e 0,48 para o experimento C4.

Na sequência ocorreu empate dos experimentos C5, C6, C7, C9 a C11 e C14 a C19, com o valor de 100% de acurácia.

O classificador obteve 0,78 de acurácia em C8 e os experimentos C11 e C12 apresentaram o valor de 0,98 de acurácia. O experimento C20 recebeu o valor de 0,71. Todas as acurácias apontadas pelo KNN estão representadas no gráfico da figura 30.

Na tabela 18, são demonstrados os resultados de acurácia, desvio padrão e variância.

Figura 30 – Gráfico das acurácias do basalto + Granito - KNN



Fonte: O Autor (2021)

Tabela 18 – Resultados de classificação KNN para basalto + Granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,56	0,02	0,0
C2	0,57	0,02	0,0
C3	0,52	0,01	0,0
C4	0,48	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,75	0,02	0,0
C9	1,00	0,00	0,0
C10	1,00	0,00	0,0
C11	1,00	0,02	0,0
C12	0,98	0,01	0,0
C13	0,98	0,01	0,0
C14	1,00	0,00	0,0
C15	1,00	0,00	0,0
C16	1,00	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,71	0,01	0,0

Fonte: O Autor (2021)

4.1.12 Acurácia do Basalto + Granito - NB

Segundo o teste de Nemenyi (tabela A12), existe diferença estatística entre o experimento C1 e os experimentos C6, C11, C14, C17, C18, C19 e C20.

O experimento C2 apresenta diferença estatística em relação aos experimentos C6, C7, C8, C10, C11, C12, C13, C14, C17, C18, C19 e C20. Em C3, a diferença acontece em relação a C6, C10, C11, C13, C14, C17, C18, C19, C20.


O teste revelou a diferença estatística entre C4 e os experimentos C6, C14, C18, C19 e C20. O teste estatístico mostrou diferença entre C5, C9 e C21. Foi possível observar que C8 difere de C14, C18, C19 e C20. Por fim, C13 se difere de C16 e C20, segundo o teste de Nemenyi.

O desempenho do classificador NB foi testado para a base unificada, demonstrando os resultados a seguir: C1 recebeu 0,40 de acurácia, seguido de 0,28 para C2 e 0,37 para C3. Houve empate nos experimentos C4 e C8 com o valor de 0,46.

Os experimentos C5, C13, C17, C18 e C19 obtiveram o valor de acurácia de 0,61. O classificador mostrou novamente empate entre C6, C7, C9, C11 e C12 que receberam o valor de 0,57 de acurácia. Os experimentos C10 e C16 obtiveram 0,58 de acurácia.

Em relação ao experimento C14, o valor obtido foi de 0,56 e de 0,55 para C15. Finalizando, o valor de C20 foi de 0,41 de acurácia. Os dados de acurácia são mostrados no gráfico da figura 31, da mesma forma que a tabela 19 traz desvio padrão e variância, além da acurácia.

Figura 31 – Gráfico das acurácias do basalto + Granito - NB



Fonte: O Autor (2021)

Tabela 19 – Resultados de classificação NB para basalto + Granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,40	0,02	0,0
C2	0,28	0,01	0,0
C3	0,37	0,01	0,0
C4	0,46	0,01	0,0
C5	0,61	0,02	0,0
C6	0,57	0,02	0,0
C7	0,57	0,01	0,0
C8	0,46	0,02	0,0
C9	0,57	0,01	0,0
C10	0,58	0,01	0,0
C11	0,57	0,02	0,0
C12	0,57	0,02	0,0
C13	0,61	0,01	0,0
C14	0,56	0,02	0,0
C15	0,55	0,01	0,0
C16	0,58	0,01	0,0
C17	0,61	0,02	0,0
C18	0,61	0,02	0,0
C19	0,61	0,02	0,0
C20	0,41	0,01	0,0

Fonte: O Autor (2021)

4.1.13 Acurácia do Basalto + Granito - DT

Segundo o teste de Nemenyi (tabela A12) percebe-se que os experimentos C1 e C3 apresentam diferença estatística com C5, C6, C7, C9, C10, C11, C12, C13, C17 e C18. O experimento C2 se difere de C5, C7, C9, C10, C11, C12, C13, C17 e C18.

Em relação a C4, a diferença aparece em C5, C7, C9, C10, C11, C12, C13. Os experimentos C5 e C7 se diferenciam apenas de C20. O teste estatístico também mostrou que C8 se difere de C9, C10, C11, C12 e C13.

Por fim, os experimentos C9, C10, C11 e C12 apresentam diferença estatística com o experimento C20.


Classificando os dados de basalto + Granito, a árvore de decisão mostrou os seguintes valores: Experimento C1 recebeu 0,59 de acurácia, C2 obteve 0,66 e o experimento C3 mostrou o valor de 0,58. Na sequência o experimento C4 apontou 0,68 de acurácia.

Em C5, C7, C10 e C12, a acurácia foi de 0,95. Os experimentos C6, C13, C17 e C18 apontaram 0,94 de acurácia. O valor de 0,79 foi atribuído ao experimento C8.

O valor de 0,96 de acurácia foi obtido pelos experimentos C9, C11 e C14. O experimento C15 apontou 0,92 de acurácia e 0,93 para os experimentos C16 e C19.

Por fim, o classificador obteve o valor de 0,70 de acurácia para o experimento C20. As acurácias apontadas pela árvore de decisão estão representadas na figura 32.

Figura 32 – Gráfico das acurácias do basalto + Granito - DT



Fonte: O Autor (2021)

De forma resumida, as informações de acurácia, desvio padrão e variância são mostradas na tabela 20.

Tabela 20 – Resultados de classificação DT para basalto + Granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,59	0,02	0,0
C2	0,66	0,02	0,0
C3	0,58	0,02	0,0
C4	0,68	0,02	0,0
C5	0,95	0,01	0,0
C6	0,94	0,01	0,0
C7	0,95	0,02	0,0
C8	0,79	0,02	0,0
C9	0,96	0,01	0,01
C10	0,95	0,00	0,0
C11	0,96	0,01	0,0
C12	0,95	0,01	0,0
C13	0,94	0,01	0,0
C14	0,96	0,01	0,0
C15	0,92	0,02	0,0
C16	0,93	0,01	0,0
C17	0,94	0,01	0,0
C18	0,94	0,01	0,0
C19	0,93	0,01	0,0
C20	0,70	0,01	0,0

Fonte: O Autor (2021)

4.1.14 Acurácia do Basalto + Granito - MLP

Os experimentos C1 e C2 se diferem estatisticamente de C11, C12, C14, C17, C18 e C19. Há diferença estatística entre C3 e C5, C11, C12, C14, C17, C18 e C19. Para C4, existe diferença em relação a C11, C14, C17, C18 e C19.

O teste revelou diferença entre C5 e C7, C13, C16, e C20. Os experimentos C7 e C13 são diferentes entre si, segundo Nemenyi (tabela A14).


Segundo o teste estatístico, C7 é diferente de C11, C12, C14, C15, C19, C18 e C19. Ao avançar para o experimento C10, percebe-se diferença em relação a C11, C14, C17, C18 e C19. Para C11, os experimentos C13, C16 e C20 são estatisticamente diferentes. O teste de Nemenyi mostrou diferença entre C12 e C13, C16 e C20. O teste revelou que C13 é diferente de C14, C17, C18 e C19. C14 se diferencia de C16 e C20.

Por fim C16 se difere em relação a C17, C18 e C19, enquanto C17, C18 e C19 se diferem de C20.

O desempenho do classificador MLP, mostrado na figura 33, para as bases unificadas, está descrito a seguir: Os experimentos C1 e C11 receberam o valor de 0,69 de acurácia, seguidos de 0,68 para C2, 0,62 para C3 e 0,80 para C4.

Houve empate nos valores de acurácia dos experimentos C5, C12, C18, C19 e C20 que alcançaram 100%. O classificador apontou 0,98 de acurácia para C6, C7 e C13. O experimento C8 obteve 0,54 de acurácia contra 0,92 obtidos por C9. O experimento C10 obteve 0,85 e em C11 resultou 0,69 de acurácia. O MLP alcançou 0,59 para o experimento C15, uma acurácia de 0,95 para C16 e 0,62 para C17.

Figura 33 – Gráfico das acurácias do basalto + Granito - MLP



Fonte: O Autor (2021)

Tabela 21 – Resultados de classificação MLP para basalto + Granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,69	0,02	0,0
C2	0,68	0,01	0,0
C3	0,64	0,01	0,0
C4	0,68	0,02	0,0
C5	1,00	0,00	0,0
C6	0,98	0,01	0,0
C7	0,54	0,11	0,0
C8	0,92	0,08	0,0
C9	0,85	0,01	0,01
C10	0,69	0,00	0,0
C11	1,00	0,00	0,0
C12	0,98	0,03	0,0
C13	0,59	0,08	0,01
C14	1,00	0,00	0,0
C15	0,95	0,08	0,01
C16	0,62	0,07	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,64	0,01	0,0

Fonte: O Autor (2021)

4.1.15 Acurácia do Basalto + Granito - RF

Segundo Nemenyi (tabela A15), C1, C2 e C3 apresentam diferença estatística em relação a C5, C6, C7, C9, C10, C11, C14, C17, C18 e C19.

C4 se difere de C5, C6, C7, C9, C10, C14, C17, C18 e C19. Os experimentos C5 e C6 se diferem de C8 e C20, enquanto C7 é diferente de C20.

Há diferença estatística entre C8 e C9, C10, C17, C18 e C19. Por fim, o teste de Nemenyi mostrou diferença entre os experimentos C9, C10, C11, C14, C17, C18, C19 e C20.

Finalizando o experimento do grupo A, com a base unificada, o *Random Forest* apontou os seguintes valores de acurácia: em C1 o valor obtido foi de 0,70, seguido

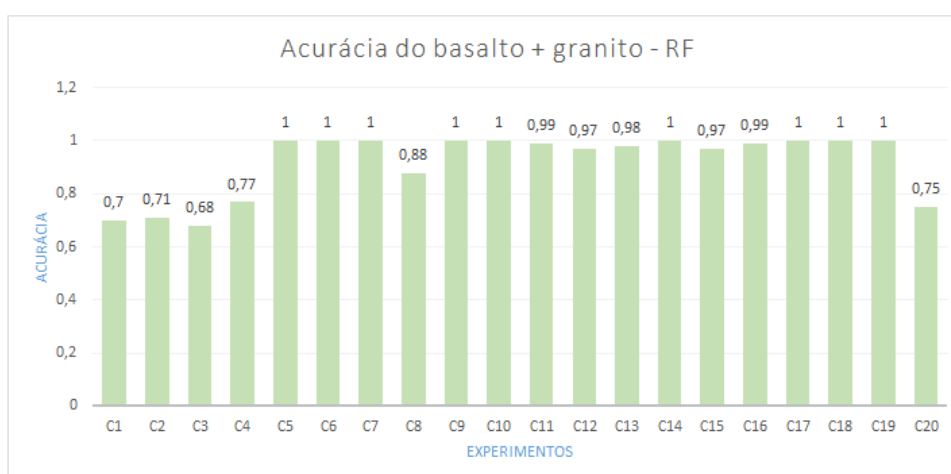
de 0,71 em C2.

O experimento C3 obteve 0,68 e C4 recebeu 0,77 de acurácia. Houve empate entre os experimentos C5, C6, C7, C9, C10, C14, C17, C18 e C19, onde o valor de acurácia chegou a 100%.

O experimento C8 recebeu 0,88, C11 e C16 foram classificados com 0,99 de acurácia.

Para os experimentos C12 e C15 o valor da acurácia foi de 0,97. C13 recebeu 0,98 e, por fim, C20 recebeu o valor de 0,75 de acurácia. Todos os dados de acurácia são mostradas no gráfico da figura 34.

Figura 34 – Gráfico das acurácias do basalto + Granito - RF



Fonte: O Autor (2021)

A seguir, na tabela 22 são mostrados os resultados de classificação, o desvio padrão e a variância apontados pelo RF.

Tabela 22 – Resultados de classificação RF para basalto + Granito

Experimento	Acurácia	Desvio Padrão	Variância
C1	0,70	0,01	0,0
C2	0,71	0,01	0,0
C3	0,68	0,01	0,0
C4	0,77	0,02	0,0
C5	1,00	0,00	0,0
C6	1,00	0,00	0,0
C7	1,00	0,00	0,0
C8	0,88	0,01	0,0
C9	1,00	0,00	0,01
C10	1,00	0,00	0,0
C11	0,99	0,00	0,0
C12	0,97	0,01	0,0
C13	0,98	0,01	0,0
C14	1,00	0,00	0,0
C15	0,97	0,01	0,0
C16	0,99	0,00	0,0
C17	1,00	0,00	0,0
C18	1,00	0,00	0,0
C19	1,00	0,00	0,0
C20	0,75	0,01	0,0

Fonte: O Autor (2021)

4.2 GRUPO B

Conforme descrito na seção 3.3 do capítulo 3, os dados testados nesse grupo, consideram a imagem completa do agregado, desconsiderando o fundo (escuro).

4.2.1 Acurácia do Basalto - KNN

Analisando o teste estatístico de Nemenyi (tabela B16), é possível verificar que C1, C2, C3 e C4 apresentam diferenças estatísticas em relação a C6, C7, C10, C12, C13, C15 e C16.


O experimento C6 se difere de C8, enquanto C7 se difere de C8 e C20. Há diferença estatística entre C8 e os experimentos C10, C12, C13, C15 e C16. Por fim, os experimentos C13 e 16 se diferem de C20, segundo o teste de Nemenyi.

Seguindo a mesma ordem adotada, nessa etapa, o KNN classificou os dados do basalto onde os resultados foram os seguintes: Os experimentos C1, C2, C3, C4 e C8 obtiveram uma acurácia de 0,98. O valor de 0,76 de acurácia foi atribuído aos experimentos C5, C11, C14, C17, C18 e C19.

Ocorreu empate nas acurácias dos experimentos C6, C12 e C15, que receberam o valor de 0,73. A acurácia calculada para os experimentos C7, C13 e C16 foi de 0,69. O experimento C9 obteve uma acurácia de 0,77, e o valor de 0,74 foi atribuído ao experimento C10.

Por fim, o experimento C20 recebeu o valor de 0,82 de acurácia do classificador KNN. Os valores estão representados no gráfico da figura 35.

Figura 35 – Gráfico das acurácias do basalto - KNN



Fonte: O Autor (2021)

O desempenho do classificador pode ser conferido na tabela 23, onde a acurácia, o desvio padrão e a variância são mostradas.

Tabela 23 – Resultados de classificação KNN para basalto

Experimento	Acurácia	Desvio padrão	Variância
C1	0,98	0,02	0
C2	0,98	0,02	0
C3	0,98	0,02	0
C4	0,98	0,02	0
C5	0,76	0,04	0
C6	0,73	0,04	0
C7	0,69	0,06	0
C8	0,98	0,02	0
C9	0,77	0,06	0
C10	0,74	0,05	0
C11	0,76	0,04	0
C12	0,73	0,04	0
C13	0,69	0,06	0
C14	0,76	0,04	0
C15	0,73	0,04	0
C16	0,69	0,06	0
C17	0,76	0,04	0
C18	0,76	0,04	0
C19	0,76	0,04	0
C20	0,82	0,06	0

Fonte: O Autor (2021)

4.2.2 Acurácia do Basalto - NB

O teste estatístico (tabela B17) apontou diferença entre os experimentos C1, C2, C3 e C4 em relação a C5, C6, C7, C11, C12, C14, C15, C17, C18 e C19. Os experimentos C5 e C6 apresentaram diferença estatística em relação a C8 e C13, enquanto C7, se diferencia de C8, C10, C13, C16 e C20.

Para os dados do experimento C8 há diferença em comparação há C9, C11, C12, C14, C15, C17, C18 e C19. O teste de Nemenyi revelou diferença estatística dos experimentos C11 e C12 em relação ao experimento C13. Outra diferença encontrada foi entre C13 e os experimentos C14, C15, C17, C18 e C19, quando comparados em pares.

Para os demais experimentos, o teste mostrou que não existe diferença estatística.


Os resultados do basalto para o classificador NB foram os seguintes: Experimentos C1, C2, C3, C8 e C13 receberam o valor de 0,98 de acurácia. C4 recebeu o valor de 0,97. Com o valor de 0,50 de acurácia aparecem os experimentos C5, C6, C12, C14, C15, C17, C18 e C19.

O experimento C7 foi classificado com 0,38 de acurácia. O valor de 0,51 de acurácia foi atribuído ao experimento C9. Em C10 o valor foi de 0,55 e 0,76 para C11.

Por fim, o experimento C16 recebeu 0,96, enquanto o experimento C20 foi avaliado pelo classificador recebendo o valor de 0,57 de acurácia. Os valores calculados pelo classificador estão dispostos em gráfico, na figura 36.

A tabela 24 mostra a acurácia, desvio padrão e variância dos resultados do NB.

Figura 36 – Gráfico das acurácias do basalto - NB



Fonte: O Autor (2021)

Tabela 24 – Resultados de classificação NB para basalto

Experimento	Acurácia	Desvio padrão	Variância
C1	0,98	0,02	0
C2	0,98	0,02	0
C3	0,98	0,02	0
C4	0,97	0,03	0
C5	0,5	0,05	0
C6	0,5	0,05	0
C7	0,38	0,07	0,01
C8	0,98	0,02	0
C9	0,51	0,05	0
C10	0,55	0,05	0
C11	0,76	0,04	0
C12	0,5	0,05	0
C13	0,98	0,02	0
C14	0,5	0,05	0
C15	0,5	0,05	0
C16	0,96	0,03	0
C17	0,5	0,05	0
C18	0,5	0,05	0
C19	0,5	0,05	0
C20	0,57	0,07	0,01

Fonte: O Autor (2021)

4.2.3 Acurácia do Basalto - DT

Analisando o resultado do teste estatístico de Nemenyi (tabela B18), é possível concluir que os experimentos C1, C2 e C4 se diferenciam em relação a C5, C7, C9, C10, C19 e C20. Já o experimento C3 apresenta diferença em comparação com C5, C6, C7, C9, C10, C17, C18, C19 e C20.

Foi possível notar diferença de C5 e C17 em relação a C11, C12, C13, C14, C15 e C16. O experimento C6 se diferencia de C16 enquanto C8 é diferente de C9, C10, C19 e C20. O experimento C9 é estatisticamente diferente de C11, C12, C13, C14, C15 e C16.

No mesmo teste, percebe-se que C10 é diferente de C13 e C16, e os experimentos C11, C12, C14 e C15 são diferentes de C20. Por fim, os experimentos C13 e


C16 são diferentes de C19 e C20.

A seguir os resultados da classificação da árvore de decisão, nos dados do basalto: Os experimentos C1, C2, C4, C8 e de C11 a C16 obtiveram o valor de 0,98 de acurácia. O experimento C3 recebeu 0,99 de acurácia e o experimento C5 alcançou 0,79.

Ambos os experimentos C6 e C19 foram classificados com uma acurácia de 0,81, enquanto o valor de 0,74 foi atribuído para C7. Para os experimentos C9 e C20 o classificador atribuiu uma acurácia de 0,78.

A acurácia de 0,71 foi o resultado para C10. Para finalizar, os experimentos C17 e C18 receberam 0,82 de acurácia. Essas informações estão representadas no gráfico da figura 37.

Figura 37 – Gráfico das acurácias do basalto - DT



Fonte: O Autor (2021)

As informações dessa classificação estão demonstradas na tabela 25.

Tabela 25 – Resultados de classificação DT para basalto

Experimento	Acurácia	Desvio padrão	Variância
C1	0,98	0,01	0
C2	0,98	0,02	0
C3	0,99	0,01	0
C4	0,98	0,01	0
C5	0,79	0,07	0
C6	0,81	0,06	0
C7	0,74	0,05	0
C8	0,98	0,02	0
C9	0,78	0,05	0
C10	0,71	0,06	0
C11	0,98	0,02	0
C12	0,98	0,02	0
C13	0,98	0,02	0
C14	0,98	0,02	0
C15	0,98	0,02	0
C16	0,98	0,01	0
C17	0,82	0,07	0
C18	0,82	0,06	0
C19	0,81	0,06	0
C20	0,78	0,05	0

Fonte: O Autor (2021)

4.2.4 Acurácia do Basalto - MLP

O teste de Nemenyi (tabela B19), que compara os experimentos em pares, mostrou que C1 se difere de C5, C6, C7, C13, C14, C15, C16 C17 e C19.

Os experimentos C2 e C4 se diferem de C5, C6, C7, C13, C14, C15, C16,e C19, enquanto C3 se difere de C5, C6, C7, C11, C13, C14, C15, C16 C17 e C18.

O conjunto de dados de C6 e C7 se diferem de C8 segundo o teste estatístico. O experimento C8 se difere de C11, C13, C14, C15, C16, C17 e C19. Todos os demais não apresentaram diferença estatística.


Os resultados para o basalto, submetido a classificação MLP, apontaram as seguintes acurácias: O valor de 0,98 de acurácia foi atribuído para C1, C3 e C8, seguido de 0,97 para C2 e C4.

O experimento C5 apontou 0,44 de acurácia, 0,57 para C6 e 0,42 para C7. A acurácia apontada para o experimento C9 foi de 0,72 e para C10 foi de 0,75. O classificador apontou para 0,56 de acurácia no experimento C11 e 0,62 para o experimento C12.

Em C13 o resultado foi de 0,45 de acurácia. O valor de 0,53 foi atribuído para os experimentos C14 e C15. O valor de acurácia do experimento C16 foi 0,39 enquanto o valor de 0,50 foi atribuído para C17.

Por fim, C18 recebeu 0,61, C19 recebeu 0,55 e C20 apontou 0,57 de acurácia. As acurácias estão dispostas em forma de gráfico, observadas na figura 38. As informações de desvio padrão, variância e acurácia são mostradas na tabela 26.

Figura 38 – Gráfico das acurácias do basalto - MLP



Fonte: O Autor (2021)

Tabela 26 – Resultados de classificação MLP para basalto

Experimento	Acurácia	Desvio padrão	Variância
C1	0,99	0,02	0
C2	0,97	0,02	0
C3	0,98	0,02	0
C4	0,97	0,02	0
C5	0,44	0,17	0,03
C6	0,57	0,13	0,02
C7	0,42	0,15	0,02
C8	0,98	0,02	0
C9	0,72	0,13	0,02
C10	0,75	0,13	0,02
C11	0,56	0,11	0,01
C12	0,62	0,06	0
C13	0,45	0,14	0,02
C14	0,53	0,14	0,02
C15	0,53	0,14	0,02
C16	0,39	0,10	0,01
C17	0,50	0,05	0
C18	0,61	0,14	0,02
C19	0,55	0,12	0,02
C20	0,57	0,08	0,01

Fonte: O Autor (2021)

4.2.5 Acurácia do Basalto - RF

O teste de Nemenyi revelou que o experimento C1 se difere de C5, C6, C7, C9, C10 e C20 enquanto C2 e C3 apresentam diferença em relação a C7 e C20.

O teste mostrou diferença entre C4 e os experimentos C5, C7, C9, C10 e C20. Para os dados de C5 e C7, a diferença aparece em relação a C8, C11, C12, C13, C14, C15 e C16.

O experimento C8 apresenta diferença estatística em comparação á C9, C10 e C20. O teste de Nemenyi (tabela B20) mostrou que C9 e C10 são diferente de C11, C12, C13, C14, C15 e C16.

Os experimentos C11, C12 e C13 são diferente de C8 e C20. Por fim, C14, C15 e C16 apresentam diferença estatística com o experimento C20.

O *Random Forest* apresentou os seguintes resultados dos agregados de basalto: os experimentos C1, C2, C3, C4, C12, C14 e C16 apresentaram o mesmo valor de acurácia de 0,99.

O RF classificou os experimentos C5 e C10 com o valor de 0,88. Repetiu o valor 0,89 de acurácia para os experimentos C6 e C19. No processo de classificação de C7 e C20, o valor foi de 0,80.


O valor máximo de 1,00 foi atribuído para C8, C11, C13 e C15. O classificador retornou o valor de 0,86 para o experimento C9.

Por fim, os experimentos C17 e C18 receberam o valor de acurácia de 0,90.

O resultado dos 20 experimentos classificados estão demonstrados no gráfico da figura 39.

A tabela 27 traz as informações de acurácia, desvio padrão e variância, que o classificador determinou.

Figura 39 – Gráfico das acurácias do basalto - RF



Fonte: O Autor (2021)

Tabela 27 – Resultados de classificação RF para basalto

Experimento	Acurácia	Desvio padrão	Variância
C1	0,99	0,01	0
C2	0,99	0,01	0
C3	0,99	0,01	0
C4	0,99	0,01	0
C5	0,88	0,04	0
C6	0,89	0,05	0
C7	0,80	0,04	0
C8	1,00	0,01	0
C9	0,86	0,05	0
C10	0,88	0,03	0
C11	1,00	0,01	0
C12	0,99	0,01	0
C13	1,00	0,01	0
C14	0,99	0,01	0
C15	1,00	0,01	0
C16	0,99	0,01	0
C17	0,90	0,03	0
C18	0,90	0,05	0
C19	0,89	0,03	0
C20	0,80	0,05	0

Fonte: O Autor (2021)

4.2.6 Acurácia do Granito - KNN


O teste de Nemenyi (tabela B21) apresentou diferença nos experimentos C2, C7, C8, C13, C16 em relação a C20. Os demais experimentos não apresentaram diferença estatística, segundo Nemenyi.

O classificador KNN retornou os seguintes resultados: Os experimentos C1, C7, C13 e C16 receberam o valor de 0,99 de acurácia.

Os experimentos C2 e C8 atingiram o valor de 1,00 de acurácia. Houve empate entre os experimentos C3, C5, C6, C9, C10, C11, C12, C14, C15 e C17 a C19, os quais receberam o valor de acurácia de 0,97. Por fim o experimento C20 teve uma acurácia de 0,85. Os resultados estão dispostos em gráfico, na figura 40.

Os resultados de desvio padrão e variância, além da acurácia, são mostrados

Figura 40 – Gráfico das acurácias do granito - KNN



Fonte: O Autor (2021)

na tabela A6.

Tabela 28 – Resultados de classificação KNN para granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,99	0,02	0
C2	1,00	0,02	0
C3	0,97	0,03	0
C4	0,98	0,03	0
C5	0,97	0,04	0
C6	0,97	0,04	0
C7	0,99	0,02	0
C8	1,00	0,00	0
C9	0,97	0,04	0
C10	0,97	0,04	0
C11	0,97	0,04	0
C12	0,97	0,04	0
C13	0,99	0,02	0
C14	0,97	0,04	0
C15	0,97	0,04	0
C16	0,99	0,02	0
C17	0,97	0,04	0
C18	0,97	0,04	0
C19	0,97	0,04	0
C20	0,85	0,09	0,01

Fonte: O Autor (2021)

4.2.7 Acurácia do Granito - NB

O teste de Nemenyi (tabela B22), mostra que o experimento C1 é diferente estatisticamente de C6 e C15, enquanto C2 apresenta diferença com C6, C12, C15 e C20.

O experimento C4 apresenta diferença estatística em relação a C6, C12 e C15. Há diferença entre C6 e os experimentos C7, C8, C19, C10, C13 e C16. Os conjuntos de dados de C7 e C8 se diferem de C12, C15 e C20. O experimento C9 se difere de C12 e C15 enquanto C10 se difere de C12, C15 e C20.

O teste estatístico apresentou diferença entre C12 e os experimentos C13 e C16. Considerando o experimento C13, é possível observar diferença estatística em relação à C15 e C20.


Há diferença entre C15 e C16, e entre C16 e C20. Os demais experimentos não apresentaram diferença estatística.

Os experimentos classificados pelo algoritmo NB, mostraram os seguintes resultados de acurácia para o granito: Experimento C1 recebeu o valor de 0,95 de acurácia, enquanto os experimentos C2, C7 e C17 apresentaram o valor 0,97.

O valor de 0,94 foi atribuído ao experimento C3. Em C4 e C10 a acurácia foi de 0,96. Ocorreu empate nos valores de acurácia dos experimentos C5, C12, C15, C17, C18 e C19, os quais receberam o valor de 0,90. Também apresentaram o mesmo valor de 0,75 de acurácia, os experimentos C6 e C16.

Os experimentos C8 e C9 obtiveram o valor de 0,98 de acurácia. C11 atingiu uma acurácia de 0,99 junto com C14. Para o experimento C20, a acurácia foi de 0,81. Os resultados do classificador estão representados no gráfico da figura 41.

Figura 41 – Gráfico das acurácias do granito - NB



Fonte: O Autor (2021)

Os demais resultados de desvio padrão e variância, são mostradas na tabela 29, além dos valores de acurácia.

Tabela 29 – Resultados de classificação NB para granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,95	0,05	0
C2	0,97	0,03	0
C3	0,94	0,06	0
C4	0,96	0,05	0
C5	0,90	0,06	0
C6	0,75	0,12	0,02
C7	0,97	0,03	0
C8	0,98	0,03	0
C9	0,96	0,03	0
C10	0,99	0,02	0
C11	0,90	0,06	0
C12	0,76	0,13	0,02
C13	0,99	0,03	0
C14	0,90	0,06	0
C15	0,75	0,12	0,02
C16	0,97	0,03	0
C17	0,90	0,06	0
C18	0,90	0,06	0
C19	0,90	0,06	0
C20	0,81	0,09	0,01


Fonte: O Autor (2021)

4.2.8 Acurácia do Granito - DT

Segundo o teste estatístico, há diferença estatística quando comparados os experimentos C7, C8, C9, C10, C11, C12, C13 e C16 ao experimento C20. Nenhuma outra diferença foi apontada no teste de Nemenyi (tabela B23).

A classificação do granito resultou nos seguintes números, quando testada com a árvore de decisão: os experimentos C1, C2 e C14 receberam o valor de 0,98 de acurácia. O experimento C3 apontou uma acurácia de 0,93. O valor de 0,97 foi atribuído aos experimentos C4 e C15 e 0,96 de acurácia para os os experimentos C5, C17, C18 e C19. O classificador apontou uma acurácia de 0,99 para os experimentos de C7 a C12 e C16. Por fim, no experimento C20 a acurácia foi de 0,85, conforme mostra o gráfico da figura 42.

Figura 42 – Gráfico das acurácias do granito - DT



Fonte: O Autor (2021)

Completando as informações de classificação, a tabela 30 traz os resultados de acurácia, desvio padrão e variância.

Tabela 30 – Resultados de classificação DT para granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,98	0,03	0
C2	0,98	0,03	0
C3	0,93	0,04	0
C4	0,97	0,03	0
C5	0,96	0,04	0
C6	0,91	0,07	0
C7	0,99	0,02	0
C8	0,99	0,02	0
C9	0,99	0,02	0
C10	0,99	0,03	0
C11	0,99	0,02	0
C12	0,99	0,02	0
C13	0,99	0,03	0
C14	0,98	0,03	0
C15	0,97	0,03	0
C16	0,99	0,02	0
C17	0,96	0,03	0
C18	0,96	0,03	0
C19	0,96	0,03	0
C20	0,85	0,09	0,01


Fonte: O Autor (2021)

4.2.9 Acurácia do Granito - MLP

Há diferença estatística quando comparados os experimentos C1, C2, C3, C4, C8, C11, C15, C17 e o experimento C20. Nenhuma outra diferença estatística foi apontada no teste de Nemenyi (tabela B24).

O classificador trouxe os resultados (gráfico da figura 43), que serão descritos a seguir: a acurácia para os experimentos C1, C4, e C8 foi de 0,99. Para os experimentos C2, C3, C15 e C17 a acurácia foi de 0,98. O valor de 0,96 de acurácia foi atribuído para C5, C11 e C12. O classificador apontou uma acurácia de 0,88 para C6 e 0,91 para C7. O experimento C9 recebeu 0,95 de acurácia, 0,93 para C10.

Figura 43 – Gráfico das acurácias do granito - MLP



Fonte: O Autor (2021)

Foram atribuídos ainda, os valores de 0,89 para C13, 0,97 para C14 e 0,83 para C16. O experimento C18 apontou uma acurácia de 0,90. Para C19, a acurácia foi de 0,86 e, por fim 0,71 para o experimento C20. Os resultados de classificação MLP para granito, com as informações de acurácia, desvio padrão e variância são mostrados na tabela 31.

Tabela 31 – Resultados de classificação MLP para granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,99	0,02	0
C2	0,98	0,03	0
C3	0,98	0,04	0
C4	0,99	0,03	0
C5	0,96	0,05	0
C6	0,88	0,29	0
C7	0,91	0,18	0,03
C8	0,99	0,02	0
C9	0,95	0,10	0,01
C10	0,93	0,11	0,01
C11	0,96	0,03	0
C12	0,96	0,06	0
C13	0,89	0,15	0,02
C14	0,97	0,15	0,02
C15	0,98	0,03	0
C16	0,83	0,15	0,02
C17	0,98	0,04	0
C18	0,90	0,14	0,02
C19	0,86	0,29	0,09
C20	0,71	0,08	0,01

Fonte: O Autor (2021)

4.2.10 Acurácia do Granito - RF

O conjunto de dados do granito, quando submetidos a teste estatístico, apresentou diferença estatística quando comparados os experimentos C1, C2, C5, C12, C14, C17, C18 e C19 ao experimento C20.


Para os demais experimentos, nenhuma diferença estatística foi apontada no teste de Nemenyi (tabela B25).

Seguindo para a etapa de classificação, o algoritmo *Random Forest* determinou os seguintes números: experimentos C1, C2, C5, C7, C9, C10, C12, C13, C16, C17, C18 e C19 receberam o valor 0,99 de acurácia.

Para os experimentos C3 e C4 o valor foi de 0,97. O mesmo valor de acurácia foi atribuído para os experimentos C6, C8, C11 e C15.

O experimento C14 atingiu o valor de 1,00 de acurácia. Por fim, o experimento C20 recebeu 0,86 de acurácia. Os resultados estão dispostos em forma de gráfico, conforme a figura 44.

Figura 44 – Gráfico das acurácias do granito - RF



Fonte: O Autor (2021)

Complementando as informações de classificação, os dados de acurácia, desvio padrão e variância são exibidos na tabela 32.

Tabela 32 – Resultados de classificação RF para granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,99	0,04	0
C2	0,99	0,20	0
C3	0,97	0,04	0
C4	0,97	0,04	0
C5	0,99	0,02	0
C6	0,98	0,04	0
C7	0,99	0,03	0
C8	0,98	0,03	0
C9	0,99	0,03	0
C10	0,99	0,03	0
C11	0,98	0,03	0
C12	0,99	0,02	0
C13	0,99	0,03	0
C14	1,00	0,00	0
C15	0,98	0,04	0
C16	0,99	0,03	0
C17	0,99	0,02	0
C18	0,99	0,02	0
C19	0,99	0,02	0
C20	0,86	0,06	0

Fonte: O Autor (2021)

4.2.11 Acurácia do Basalto + Granito - KNN

Os experimentos C1, C2, C3 e C4 apresentam diferença estatística entre C6, C7, C10, C12, C13, C15, e C16.

Há diferença estatística nos experimentos C5, C6, C7 em relação a C8, enquanto C8 apresenta diferença entre C10, C11, C12, C13, C14, C15, C16, C17, C18 e C19.

Os demais experimentos não indicaram diferença estatística (tabela B26).

O basalto e o granito, juntos em uma única base, foram testados com o classificador KNN e os resultados são: experimentos C1 e C4 receberam uma acurácia de 0,97 e os experimentos C2 e C3 receberam, respectivamente, os valores de 0,98 e 0,96 de acurácia.


O valor de 0,81 de acurácia foi atribuído aos experimentos C5, C11, C14, C17, C18 e C19. O experimento C6 empatou com C10, C12 e C15 tendo cada um deles recebido o valor de 0,79 de acurácia.

O classificador atribuiu o valor de 0,75 de acurácia para os experimentos C7, C13 e C16. Para o experimento C8 foi atribuído o valor de 0,99 de acurácia.

A acurácia de 0,82 foi alcançada pelos experimentos C9 e C20.

Os valores de acurácia estão resumidos no gráfico da figura 45. Os dados de classificação, como desvio padrão e variância, completam a tabela 33, que traz a acurácia de todos os experimentos.

Figura 45 – Gráfico das acurácias do basalto + Granito - KNN



Fonte: O Autor (2021)

Tabela 33 – Resultados de classificação KNN para basalto + Granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,97	0,02	0
C2	0,98	0,01	0
C3	0,96	0,02	0
C4	0,97	0,02	0
C5	0,81	0,06	0
C6	0,79	0,05	0
C7	0,75	0,05	0
C8	0,99	0,02	0
C9	0,82	0,05	0
C10	0,79	0,05	0
C11	0,81	0,06	0
C12	0,79	0,05	0
C13	0,75	0,05	0
C14	0,81	0,06	0
C15	0,79	0,05	0
C16	0,75	0,05	0
C17	0,81	0,06	0
C18	0,81	0,06	0
C19	0,81	0,06	0
C20	0,82	0,04	0

Fonte: O Autor (2021)

4.2.12 Acurácia do Basalto + Granito - NB

O teste de Nemenyi (tabela B27) aplicado aos dados da classificação do NB, apontou diferença estatística entre os experimentos C1 e C2 e os experimentos C5, C6, C7, C11, C12, C14, C15, C17, C18, C19 e C20.

O experimento C2 se difere de C6, C11, C12, C15 e C20, enquanto o experimento C4 apresenta diferença em relação a C6, C12 e C15.

Há diferença estatística de C5 e C7 em relação a C8. Para o experimento C6, a diferença ocorre em comparação á C8, C10, C13 e C16. O teste estatístico mostrou diferença entre C8 e os experimentos C9, C11, C12, C14, C15, C17, C18, C19 e C20.

Foi possível observar diferença estatística entre C10 em relação a C12 e C15. O experimento C12 se difere de C13 e C16, da mesma forma que C13 se difere de C20. Por fim, o experimento C15 apresenta diferença estatística com C16, enquanto o experimento C20 se difere de C16.


As acurácias apontadas pelo classificador *Naive Bayes* são: experimento C1 responde por 0,93 de acurácia, enquanto C2, C13 e C16 receberam o valor de 0,86.

O valor 0,92 foi atribuído ao experimento C3, seguido de 0,79 para o experimento C4.

Os experimentos C5, C11, C14, C17, C18 e C19 apontaram uma acurácia de 0,52. O mesmo valor de acurácia, 0,48, foi atribuído aos experimentos C6, C12 e C15. O classificador atribuiu o valor de 0,50 para C7, 0,97 para C8 e 0,54 para C9. O experimento C10 pontou 0,57 de acurácia e o valor de 0,49 foi atribuído ao experimento C20.

Na figura 46, é possível observar o gráfico dos resultados da classificação do NB.

Figura 46 – Gráfico das acurácias do basalto + Granito - NB



Fonte: O Autor (2021)

Seguem os dados de acurácia, desvio padrão e variância, na tabela 34.

Tabela 34 – Resultados de classificação NB para basalto + Granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,93	0,03	0
C2	0,86	0,05	0
C3	0,92	0,03	0
C4	0,79	0,05	0
C5	0,52	0,06	0
C6	0,48	0,06	0
C7	0,50	0,08	0
C8	0,97	0,01	0
C9	0,54	0,06	0
C10	0,57	0,05	0
C11	0,52	0,06	0
C12	0,48	0,07	0
C13	0,86	0,04	0
C14	0,52	0,06	0
C15	0,48	0,07	0
C16	0,86	0,04	0
C17	0,52	0,06	0
C18	0,52	0,06	0
C19	0,52	0,06	0
C20	0,49	0,05	0

Fonte: O Autor (2021)

4.2.13 Acurácia do Basalto + Granito - DT

Ao submeter os dados ao teste estatístico, foi possível observar que o experimento C2 se difere de C5, C6, C7, C9, C10, C17, C19 e C20, enquanto C5 e C7 são diferentes de C8, C11, C12, C13, C14, C15 e C16.

O experimento C6 apresenta diferença estatística em relação a C11, C13 e C16.

Há diferença estatística entre C8 e os experimentos C9 e C20. O teste de Nemenyi (tabela B28) aponta diferença estatística entre C9 e os experimentos C11, C12, C13, C14 e C16.

O experimento C10 se difere de C11, C13 e C16. Observando o experimento C11 é possível perceber que existe diferença em relação aos experimentos C17 e C20. Há diferença, também, entre C13 e os experimentos C17, C18, C19 e C20.

Para C16, o teste mostrou diferença em comparação com C17 e C20. Por fim, os testes C12, C14 e C15 apresentam diferença estatística em relação a C20.

O algoritmo de árvore de decisão classificou os agregados de basalto e granito juntos, onde os resultados foram: experimentos C1 e C4 receberam 0,92 de acurácia, enquanto C2 e C13, o valor de acurácia foi de 0,96. Em C3, a acurácia foi de 0,93 e C5 ficou com 0,82.


A classificação retornou o valor de 0,85 em C6 e C10 e o valor de 0,80 para C7.

Com 0,95 de acurácia, aparecem os experimentos C8, C11, C12, C15, e C16. A resposta do classificador foi de 0,83 para o experimento C9 e 0,94 para C14.

Por fim, os experimentos C17 e C19 receberam uma acurácia de 0,86 e C18 e C20 receberam, 0,87 e 0,79 respectivamente.

Para melhor ilustrar os dados da classificação, o gráfico da figura 47 mostra as acurácias obtidas pelo classificador.

Figura 47 – Gráfico das acurácias do basalto + Granito - DT



Fonte: O Autor (2021)

Os dados de acurácia, desvio padrão e variância, são mostrados na tabela 35.

Tabela 35 – Resultados de classificação DT para basalto + Granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,92	0,03	0
C2	0,96	0,01	0
C3	0,93	0,03	0
C4	0,92	0,03	0
C5	0,82	0,05	0
C6	0,85	0,05	0
C7	0,80	0,05	0
C8	0,95	0,03	0
C9	0,83	0,05	0
C10	0,85	0,04	0
C11	0,95	0,03	0
C12	0,95	0,03	0
C13	0,96	0,02	0
C14	0,94	0,03	0
C15	0,95	0,04	0
C16	0,95	0,02	0
C17	0,86	0,06	0
C18	0,87	0,05	0
C19	0,86	0,05	0
C20	0,79	0,05	0

Fonte: O Autor (2021)

4.2.14 Acurácia do Basalto + Granito - MLP

O teste de Nemenyi (tabela B29) mostrou que C1 e C3 apresentam diferença estatística entre C7, C11, C12, C13, C14, C15, C16 e C18, enquanto C2 é diferente

dos experimentos C5, C6, C7, C11, C12, C13, C14, C15, C16, C17, C18, e C19.

O experimento C4 é diferente estatisticamente de C7, C13, C16 e C19 e os experimentos C5 e C6 são diferentes de C8.

O teste mostrou diferença estatística entre C7 e C8, C9 e C10. No experimento C8 foi possível observar diferença em relação á C11, c12, C13, C14, C15, C16, C17, C18 e C19.

Há diferença estatística entre C9 e os experimentos C9 e C16. Por fim, C16 é diferente de C20 segundo Nemenyi.

A classificação com MLP obteve os seguintes resultados: os experimentos C1 e C3 receberam uma acurácia de 0,97, enquanto C2 e C4 receberam 0,98 e 0,94, respectivamente.


Os experimentos C5, C14, C15 e C19 apontaram o valor de 0,74 de acurácia enquanto C6 apresentou 0,70 e C7 0,58. A acurácia do experimento C8 foi de 0,99 e de C9 foi de 0,88. Com 0,84 de acurácia apareceu o experimento C10.

Atribuiu-se aos experimentos C11 e C18 o valor de 0,75 e para C12 e C13 os valores de 0,72 e 0,62 respectivamente.

Finalizando, o experimento C16 recebeu 0,53, já o experimento C17 recebeu 0,76 e o valor 0,80 foi a acurácia do experimento C20.

Todos os resultados dos 20 experimentos estão demonstrados no gráfico da figura 48.

Figura 48 – Gráfico das acurácias do basalto + Granito - MLP



Fonte: O Autor (2021)

Para a mesma classificação, estão agrupados na tabela 36, os dados de acurácia, desvio padrão e variância.

Tabela 36 – Resultados de classificação MLP para basalto + Granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,97	0,02	0
C2	0,98	0,01	0
C3	0,97	0,02	0
C4	0,94	0,03	0
C5	0,74	0,06	0
C6	0,70	0,07	0
C7	0,58	0,09	0
C8	0,99	0,02	0
C9	0,88	0,04	0
C10	0,84	0,05	0
C11	0,75	0,06	0
C12	0,72	0,08	0
C13	0,62	0,07	0
C14	0,74	0,05	0
C15	0,74	0,04	0
C16	0,53	0,12	0
C17	0,76	0,07	0
C18	0,75	0,07	0
C19	0,74	0,08	0
C20	0,80	0,04	0

Fonte: O Autor (2021)

4.2.15 Acurácia do Basalto + Granito - RF

O experimento C1 é estatisticamente diferente de C7 e C20, enquanto C2 se difere de C5, C6, C7, C19, C10, C17, C18 e C20.

Em C4, é possível verificar diferença apenas com C20. No experimento C5, há diferença em relação a C11, C12 e C13 segundo o teste de Nemenyi (tabela B30).

Considerando o experimento C6, o teste demonstrou diferença em comparação a C8, C11, C12 e C13. O teste estatístico mostrou que C7 se difere de C8, C11, C12, C13, C14, C15 e C16.

Há diferença estatística entre C8 e os experimentos C9, C10, C17, C19 e C20, enquanto em C9 a diferença é percebida em relação a C11, C12, C13, C14 e C16.

Ambos os experimentos C11 e C12 apresentam diferença em comparação a C17, C19 e C20.

Por fim C13 se difere de C17, C18, C19 e C20 enquanto C14, C15 e C16 são estatisticamente diferente de C20.

O algoritmo *Random Forest* apresentou os seguintes resultados: C1 recebeu uma acurácia de 0,97. O valor de 0,99 de acurácia foi atribuído para os experimentos C2, C8, C11, C12, C14, e C16.


Os experimentos C3 e C4 receberam 0,96 de acurácia. O valor de 0,91 de acurácia foi atribuído aos experimentos C5, C6, C10 e C17.

Os valores de 0,85 e 0,89 foram atribuídos aos experimentos C7 e C9. A acurácia de 1,00 foi alcançada pelo experimento C13. O classificador apontou uma acurácia

de 0,98 para C15.

Por fim, C18 e C19 receberam 0,92 de acurácia, enquanto o valor de 0,82 foi o resultado de C20. Os resultados dos 20 experimentos estão resumidos no gráfico da tabela 49.

Figura 49 – Gráfico das acurácias do basalto + Granito - RF



Fonte: O Autor (2021)

Para finalizar, estão compilados os dados de variância, desvio padrão e a acurácia dos experimentos, na tabela 37.

Tabela 37 – Resultados de classificação RF para basalto + Granito

Experimento	Acurácia	Desvio padrão	Variância
C1	0,97	0,02	0
C2	0,99	0,01	0
C3	0,96	0,02	0
C4	0,96	0,03	0
C5	0,91	0,04	0
C6	0,91	0,04	0
C7	0,85	0,03	0
C8	0,99	0,01	0
C9	0,89	0,05	0
C10	0,91	0,04	0
C11	0,99	0,01	0
C12	0,99	0,01	0
C13	1,00	0,00	0
C14	0,99	0,01	0
C15	0,98	0,01	0
C16	0,99	0,01	0
C17	0,91	0,03	0
C18	0,92	0,03	0
C19	0,92	0,03	0
C20	0,82	0,04	0

Fonte: O Autor (2021)

4.3 CONSIDERAÇÕES FINAIS

Os resultados da frequência de tons de cinza mostraram-se capazes de classificar as imagens, separando em classes com uma precisão superior a 50% nos experimentos com o basalto quando testado considerando apenas uma amostra da imagem (grupo A). Para as imagens completas, desconsiderando o fundo, o desempenho do descritor foi superior a 97% para o agregado de basalto. Quando colocado à prova na base composta (basalto + granito) o descritor se mostrou eficiente atingindo valores entre 40% e 70% de acerto para imagens do grupo A e chegando a 97% de acerto no grupo B. Em relação ao granito, quando testado isoladamente, pelo descritor de frequência de tons de cinza, apresentou desempenho superior a 76%, chegando a 83% de acerto nas classificações de imagens do grupo A. Os resultados para o grupo B foram superiores, passando de 98% para todos os classificadores.

A frequência do canal R, testada isoladamente, no processo de classificação, mostrou resultados que variaram entre 49% e 65% de acerto para o grupo A. Para o grupo B, os resultados do descritor para o basalto mostraram um desempenho superior a 98% de acerto. A investigação do granito, utilizando o mesmo descritor, apontou resultados entre 65% e 90% de acerto nas imagens do grupo A. Resultados superiores foram observados no grupo B, onde os classificadores apontaram precisão de 97% e 100% nas classificações realizadas. Quando o basalto e o granito foram testados juntos, os resultados variaram de 28% a 71% de acerto, no grupo A. No grupo B, os resultados foram de 86% até 99% de acerto.

Outro descritor testado isoladamente, a frequência do canal G, revelou resultados entre 34% e 67% para a classificação do basalto, considerando os experimentos do grupo A. A performance desse descritor melhorou quando aplicado ao grupo B. Os resultados revelaram índices de acerto acima de 98% em todos os resultados. O desempenho do descritor, quando aplicado ao granito, passou de 67% e teve o maior índice, atingindo 81% de acerto nos experimentos pertencentes ao grupo A. A tendência de acerto aumentou quando os testes foram realizados com o conjunto de imagens do grupo B. Os resultados de acerto variaram de 93% a 98%, se mostrando muito promissor para classificar o granito. Quando experimentado usando a base composta (basalto + granito), os classificadores foram capazes de acertar a partir de 37% até 68% para o grupo A. Nos teste do grupo B, os classificadores foram mais precisos, alcançando índices entre 92% e 96% de acerto.

O desempenho do descritor de frequência do canal B, se mostrou promissor para classificação do basalto, apresentando desempenho que variou de 53% a 81% de acerto, para a base de imagens do grupo A. O descritor apresentou uma maior precisão quando submetido à classificação utilizando imagens do grupo B onde o desempenho foi de 97% a 99% de acerto. Os resultados de classificação do granito

para o grupo A, foram de 78% a 81% de acerto. O descritor de frequência do canal B foi superior em precisão quando testado a partir de imagens do grupo B. Seu desempenho variou de 93% a 99% de acerto. Os testes com a base composta mostraram que o desempenho para o grupo A variou de 46% a 80% de acerto, um resultado inferior aos valores obtidos nos testes com o grupo B, que variou de 79% a 97%.

O descritor LBP apresentou desempenhos animadores para os experimentos envolvendo o basalto. Para o grupo A, os índices de acerto variaram entre 66% e 100%. Para os experimentos que utilizaram as amostras do grupo B, o desempenho de classificação teve uma variação de 44% a 88% de acerto. Em relação aos experimentos envolvendo o granito, o desempenho variou entre 76% e 100% de acerto quando classificado com as amostras do grupo A. Os experimentos do grupo B, registraram desempenho mínimo de 90% e chegaram a 99% de acerto. Ao testar a base composta (basalto + granito), os resultados de classificação indicaram 61% de acerto para o menor valor e 100% de acerto em pelo menos 3 classificadores, para os experimentos do grupo A. Os classificadores retornaram valores que variavam entre 52% e 91% de acerto, para os testes envolvendo imagens do grupo B.

O descritor LBPU se mostrou eficiente quando testado nas imagens de basalto, atingindo índices entre 64% e 100% de acerto para os experimentos do grupo A. Pelo menos dois classificadores indicaram o resultado máximo. Em relação aos experimentos do grupo B, os índices alcançados foram de 50% a 89% de acerto na classificação. Para as imagens do granito, o desempenho do descritor foi de 76% de acerto (menor valor obtido) e de 100% de acerto em pelo menos 3 classificadores. Estes resultados foram obtidos a partir das imagens do grupo A. Os testes de classificação, quando utilizadas as imagens do grupo B, mostraram desempenho mínimo de 75% chegando a 98% no melhor índice. O LPBU foi testado na base composta (basalto + granito) e comparando o desempenho dos classificadores, baseado nas imagens do grupo A, os resultados revelaram que o menor índice foi de 57% e atingiu 100% de acerto, em pelo menos dois classificadores. Já para os índices dos experimentos do grupo B, o desempenho ficou entre 48% e 91% de acerto.

As matrizes de co-ocorrência (GLCM), se mostraram capazes de fornecer informações que possibilitam a classificação, segundo os resultados obtidos a partir de imagens de ambos os agregados (basalto e granito). Para os experimentos do grupo A, o basalto atingiu índices de classificação que variaram entre 56% e 100% de acerto, em pelo menos dois classificadores. Considerando as imagens do grupo B, os resultados foram de 38% para o menor valor e de 80% para o melhor índice. O granito recebeu índices promissores, quando o grupo A foi utilizado, de acordo com os resultados obtidos. Os classificadores indicaram resultados de 81% no menor valor obtido e de 100% de acerto, valor atingido por três classificadores. Observando os resultados do grupo B, os índices foram de 91%, chegando a 99% de acerto na classificação

para imagens do granito. Na base composta, os índices superaram 57% para o menor valor obtido, chegando ao resultado máximo de 100% de acerto, em pelo menos dois classificadores, para os experimentos do grupo A. O resultado dos experimentos do grupo B foram superiores a 50% no seu menor índice, chegando a 85% de acerto no melhor desempenho.

Os descritores de frequência R, G e B foram testados em conjunto, e os resultados se mostraram promissores, para ambos os tipos de agregados. Os testes das imagens do grupo A, do agregado de basalto, mostraram índices de 85% até 99% de acerto. Considerando os experimentos do grupo B, o desempenho do descritor superou 98% de acerto em quatro classificadores e chegou em 100% em um dos algoritmos de classificação. Para o granito, o desempenho foi superior a 85% no seu menor índice e atingiu 99% na melhor classificação, nos experimentos do grupo A. O desempenho foi ainda maior para o grupo B, que atingiu índices entre 98% e 100% de acerto. Os experimentos da base composta (basalto + granito) indicaram desempenho acima de 46% para o menor valor e atingiu 88% de acerto no melhor resultado, para o grupo A. Já os resultados dos experimentos do grupo B foram superiores, atingindo 95% de acerto no pior cenário e 99% no melhor desempenho, resultado apontado por três classificadores.

Avançando nos experimentos, o LBP e GLCM foram combinados e os resultados indicaram que os descritores são capazes de obter resultados animadores. Observando os experimentos do grupo A, os classificadores alcançaram índices entre 65% a 100% de acerto para o basalto. Resultados com desempenho de 51% até 86% de acerto foram observados nas classificações do grupo B. Ao testar o granito, a combinação dos descritores LBP e GLCM atingiu índices de acerto superior a 80% nos menores valores de classificação, seguidos de 100% em pelo menos três classificadores para experimentos baseados no grupo A. O desempenho dos descritores para os testes com o grupo B, indicaram valores entre 95% e 99% de acerto. Foi observado que os valores foram promissores quando testada a base composta. Para o basalto, os resultados foram de 57% de acerto, chegando a 100% de precisão na classificação do grupo A. Os experimentos do grupo B, variaram entre 54% e 89% de precisão na classificação do grau de alteração dos agregados.

Outra abordagem de combinação dos descritores envolveu o LBPU e GLCM. Os resultados foram animadores para ambos os agregados. No grupo A, o desempenho para o basalto variou entre 61% e 100% de acerto. Pelo menos dois classificadores apontaram o resultado máximo. Nos experimentos do grupo B, os resultados partiram de 55% e chegando a 88% de acerto. Em relação ao granito, os resultados apontados para o grupo A, indicaram valores partindo de 81% e alcançando 100% de precisão conforme indicaram três classificadores. Ao testar os descritores no grupo B, os resultados foram de 93% a 99% de acerto. Na base composta, os descritores foram suficientes

para indicar resultados entre 58% e 95% de acerto, no grupo A. O desempenho dos experimentos do grupo B foi de 57% para o menor resultado e de 91% de acerto no melhor índice.

Mais uma abordagem de combinação dos descritores que juntou a frequência RGB e o LBP revelou resultados animadores. Os testes com o basalto apontaram um desempenho que variou entre 61% e 100% de acerto nas classificações das imagens do grupo A. Já para o grupo B, os classificadores apontaram 56% de acerto, sendo o menor valor obtido, ao passo que foi alcançado 100% de acerto na classificação para o melhor valor. Os resultados tenderam para um maior acerto, nos experimentos do granito, onde os índices mínimos foram 92% de acerto, enquanto outros três classificadores apontaram 100% de acerto, nos experimentos do grupo A. O desempenho dos experimentos do grupo B superaram 96% e atingiram um máximo de 99% de acerto. Ao testar a base composta, os resultados foram de 57% de acerto na classificação menos expressiva e chegou a 100% em pelo menos um classificador, para o grupo A. Da mesma forma que no grupo B, os valores foram de 52% de acerto para 99% de precisão na classificação.

O descritor RGB foi testado junto com LBPU e essa combinação produziu resultados, para o basalto, que variaram entre 62% e 100% de acerto na classificação das imagens que pertencem ao grupo A. Foi possível observar índices de acerto que partiram de 50% chegando ao máximo de 99% para o grupo B. Ao observar os resultados do granito, os classificadores atingiram 92%, sendo menor índice, enquanto o total de 100% foi alcançado nos testes do grupo A. Para os experimentos que pertencem ao grupo B, os resultados variaram de 96% e 99% de acerto. Os resultados dos experimentos da base composta, trouxeram valores que partiram de 57% de acerto até o 100% no desempenho de um dos classificadores, considerando os experimentos do grupo A. Desempenho similar foi atribuído ao grupo B, que pontuou 50% de acerto, no menor índice e de 99% de acerto na classificação mais assertiva.

O desempenho dos descritores RGB e GLCM, combinados, foi de 61% de acerto e chegou em 98%, se mostrando assertivo na classificação do basalto. Esses resultados foram produzidos a partir do grupo A. Já para o grupo B, os índices partiram de 45% de acerto, no menor valor do experimento, porém, em pelo menos um classificador, o valor foi de 100% de acerto. Para os experimentos baseados nas imagens do granito, o desempenho partiu de 92% e atingiu 100% na classificação no grupo A. Desempenho similar ao grupo B, que pontuou 76% e chegou a 99% em pelo menos três classificações para o conjunto. Os índices de acerto dos experimentos da base composta, mostraram um desempenho de 61% de acerto seguido de um valor superior a 97%, se mostrando capaz de classificar os dados do grupo A. No grupo B, o desempenho foi da mesma forma interessante, pois, apesar de pontuar 45% em uma das classificações, outras chegaram em 100% de acerto.

A junção das informações de textura dos descritores de frequência de cinza e o LBP produziu resultados animadores, quando classificados usando ambos os agregados, basalto e granito. Para o grupo A, o desempenho do basalto foi de 59% no seu menor valor e de 100% de acerto para outras três classificações. Os resultados foram igualmente animadores para o grupo B, onde o menor índice apontado foi de 50% de acerto chegando a 99% de precisão. Na classificação do granito, os índices foram ainda mais promissores. Os testes do grupo A demonstraram valores que partiram de 80% de acerto e de 100% de precisão, apontada por três algoritmos. Os índices de acerto, nos testes do grupo B, foram de 97% e de 100%, indicando que os descritores, juntos, são capazes de realizar a classificação dos agregados. Nos experimentos da base composta, os resultados sugerem que os descritores são capazes de classificar com um desempenho que varia de 56% a 100% de precisão, para as imagens do grupo A, enquanto no grupo B, os índices foram de 50% e 99% de acerto.

Os resultados dos experimentos que utilizaram os descritores de frequência de tom de cinza e o LBPU, sugerem que é possível realizar a classificação de agregados de basalto e granito. Segundo os índices de classificação do basalto, o desempenho partiu de 59% de acerto, tendo ainda 100% de precisão, para o grupo A. Os classificadores foram capazes de atingir 100% de acerto, enquanto o valor de 50% foi o resultado menos expressivo nos testes do grupo B. O granito recebeu valores de classificação mais animadores, partindo de 80% e chegando a 100% de acerto, nos experimentos do grupo A. Seguindo a mesma tendência, os experimentos do grupo B, pontuaram valores entre 90% e 98% de acerto. Usando os descritores (frequência de tom de cinza e LBPU) para testar a base composta, percebe-se que, é possível utilizar para classificação, obtendo resultados promissores para os grupos, A e B. No grupo A, os índices mínimos atingiram 55% de acerto, enquanto os índices máximos chegaram a 100% em pelo menos duas classificações. Resultados similares foram alcançados pelos testes do grupo B, onde o desempenho dos classificadores partiu de 50% de acerto e chegou a 100%, demonstrando que é possível obter classificação dos agregados quanto à alteração.

Os experimentos que foram testados utilizando os descritores de frequência de tons de cinza e GLCM seguiram uma tendência otimista, para os grupos A e B. Os resultados do basalto foram superiores a 58% para a classificação menos expressiva e de 100% de acerto em uma das classificações dos experimentos do grupo A. Para o grupo B, os classificadores pontuaram valores entre 39% e 99% de acerto. O granito teve um desempenho promissor, variando entre 86% e 100% de acerto, nos experimentos do grupo A. Os resultados do grupo B demonstraram capacidade elevada de classificação, tendo o menor valor em 75% e 99% no melhor desempenho. Nas classificações utilizando a base composta, os índices apontados partiram de 58% e chegaram a 100% de acerto, em pelo menos uma classificação, considerando os dados

do grupo A. Os testes do grupo B resultaram em valores entre 69% e 99% de acerto.

Outra abordagem de combinação de descritores testou o LBP e a Entropia do canal R, onde os resultados foram animadores. No grupo A, o basalto recebeu valores de classificação que partiram de 67% de acerto e finalizaram com 100% de acerto, resultado apontado por três classificadores. No grupo B, os índices de classificação variaram entre 50% e 90% de acerto. Nos testes do granito, considerando os dados do grupo A, pelo menos três classificadores apontaram 100% de acerto e 79% de acerto na classificação menos expressiva. Os experimentos do grupo B demonstraram resultados superiores a 97% e 99% na classificação mais assertiva. Os descritores mostraram, ainda, que são capazes de classificar diferentes tipos de agregados, como as amostras da base composta, com desempenho que variam entre 52% e 100% de acerto, considerando os experimentos do grupo A. Já para o grupo B, os classificadores chegaram em resultados entre 50% e 90% de precisão.

O LBP foi combinado com a entropia do canal G, onde os resultados indicam que há possibilidade de classificação, com desempenhos animadores. Nos experimentos do basalto, do grupo A, os índices partiram de 68% chegando em 100% de acerto. Já para os experimentos do grupo B, os índices de classificação foram de 50% a 90% de acerto. Em relação ao granito, os resultados são promissores, de acordo com os classificadores que pontuaram 78% de acerto no resultado menos preciso e 100% de acerto em pelo menos três resultados, para as imagens do grupo A. Resultados igualmente animadores para o grupo B, que partiram de 90% chegando a 99% de acerto. Para a base composta, os resultados de classificação foram promissores. O basalto foi classificado com 61% de precisão, no menor resultado, do grupo A. Já o melhor desempenho foi de 100% em três das cinco classificações. No grupo B, os valores variaram de 50% a 90% de precisão.

Para os descritores LBP e entropia do canal B, os índices de classificação foram animadores, segundo os resultados de ambos os tipos de agregados. Para o basalto, considerando as imagens do grupo A, foi obtido um resultado que variou de 67% a 100% de acerto, onde pelo menos três classificadores apontaram o valor máximo. Nos experimentos do grupo B, os valores partiram de 50% chegando a 89% de acerto. O granito recebeu valores de classificação variando de 77% e 100%, onde três classificadores pontuaram o maior valor, nos experimentos do grupo A. Já para o grupo B, o desempenho de menor valor foi de 86% e o ápice chegou a 99%. Nos experimentos de imagens da base composta, considerando o grupo A, os classificadores foram capazes de atingir uma precisão de 61% em seu pior desempenho e de 100% nos melhores resultados (três classificadores). Os valores de 50% no menor resultado e 89% de acerto na melhor classificação foram apontadas nos experimentos do grupo B.

No último experimento, combinando a entropia dos canais, R, G e B, os resultados apontaram índices de classificação que variam de 52% a 76% de acerto no basalto,

para o grupo A. Foi possível observar que os resultados das imagens do grupo B, partiram de 57% chegando a 82% de acerto. Nos resultados dos experimentos com o granito, os valores apontaram de 76% de precisão, menor desempenho, passando de 80% de acerto, no maior desempenho, considerando os experimentos do grupo A. Nos testes com o granito foi verificado uma precisão de 71% no resultado menos expressivo, e 86% no melhor resultado do grupo B. Os experimentos da base composta revelaram índices de 41% de acerto, no menor valor de classificação, e 75% no maior valor, quando utilizado imagens do grupo A. Para os experimentos do grupo B, os valores apontados foram de 57% a 82% de acerto na classificação.

5 CONCLUSÃO

O projeto e a construção de estradas seguem normas específicas, que visam garantir a segurança, durabilidade e conforto para seus usuários. Para tal, a escolha de material adequado a ser empregado nas obras, requer conhecimento técnico por parte dos responsáveis. A engenharia civil dispõe ferramentas que visam garantir que o material a ser usado apresente requisitos mínimos exigidos porém, busca-se alternativas mais baratas e rápidas que agilizem o processo de escolha do material. Esse trabalho se propôs a investigar alternativas por meio de processamento digital de imagens e análise de textura de imagens.

Buscou-se, então, testar as ferramentas de análise de textura, a fim de classificar agregados minerais, a partir do grau de alteração. A investigação realizada abordou os descritores de histograma de tons de cinza, entropia de Shannon, frequência dos canais RGB, além dos descritores LBP, LBPU e GLCM. Os resultados sugerem que tais descritores são promissores na classificação de imagens de basalto e granito.

Para melhor explorar as ferramentas de análise de textura, foi proposto a criação de duas bases de imagens, a partir da base original, onde uma das bases, nomeada de grupo A, fosse testada considerando apenas uma amostra do agregado e a outra base, nomeada de grupo B, onde o agregado completo fosse avaliado, excluindo a região do fundo da imagem (região escura), através do processo de limiarização. Aprofundou-se os testes avaliando os tipos de agregados separadamente e por fim, juntando ambos (granito + basalto).

A observação dos resultados sugeriram que as ferramentas de análise de textura LBP, LBPU e GLCM foram mais promissoras para classificação quando submetidas aos experimentos do grupo A, principalmente se utilizadas em combinação com os algoritmos KNN e RF. Já para os experimentos do grupo B, a frequência dos tons de cinza, as frequências dos canais R, G e B testadas isoladamente, ou quando agrupadas, e a entropia dos canais R, G e B, demonstraram serem mais efetivas para classificação através dos algoritmos KNN, DT e RF.

Os experimentos demonstraram que é possível obter a classificação dos agregados quanto a sua alteração utilizando agregados de naturezas diferentes, levando-se em conta que cada tipo de agregado apresenta graus de alteração característicos. Ademais, observou-se que tanto utilizando o agregado completo quanto amostras, foi possível obter a classificação. Dessa forma, em ambiente de produção, onde o agregado é transportado em esteiras, existe a possibilidade de se obter imagens e a partir delas classificar os agregados, processo que pode auxiliar na escolha de material adequado para a construção civil.

De maneira geral, os descritores utilizados mostraram tendência de classificação de agregados quanto à alteração, com índices de acerto promissores. Os descritores

aceitam parâmetros que influenciam o desempenho da classificação, que não foram explorados na sua totalidade nesta pesquisa e que podem contribuir para melhores resultados em experimentos futuros. Da mesma forma, os algoritmos de classificação podem variar o desempenho, quando se utiliza de ajustes específicos, os quais não foram explorados neste trabalho.

Em pesquisas futuras, outros tipos de agregados podem ser utilizados, colocando os descritores à prova. Ajustes nos descritores de frequência RGB, como a utilização de pesos atribuídos aos valores de frequência, por exemplo. A utilização da entropia de imagens em tons de cinza é uma alternativa a ser estudada. Em relação aos descritores LBP e LBPU, os canais de cor B ou G podem ser explorados. Para as matrizes de co-ocorrência, as distâncias e os ângulos podem gerar outros resultados para imagens com resolução maiores.

Por fim, a entropia dos canais R, G e B podem ser combinadas com os descritores RGB, LBPU, GLCM e frequência de tons de cinza, possibilidades que podem contribuir para a tarefa de classificação de agregados e acrescentar conhecimento para a área da construção de estradas e pavimentos.

REFERÊNCIAS

- ALBERTINI, M. K.; MELLO, R. F. A self-organizing neural network for detecting novelties. In: **Proceedings of the 2007 ACM symposium on Applied computing**. São Paulo: [s.n.], 2007. p. 462–466.
- ALI, H. *et al.* Symptom based automated detection of citrus diseases using color histogram and textural descriptors. **Computers and Electronics in agriculture**, v. 138, p. 92–104, 2017.
- ANDRADE, E. C. d. **Processamento digital de imagens como estimativa de teor de n foliar na cultura do milho**. 56 p. Dissertação (Mestrado em Computação Aplicada) — Universidade Estadual de Ponta Grossa, Ponta Grossa, 2015. Disponível em <http://tede2.uepg.br>. Acesso em: 2 dez. 2020.
- ARMI, L.; FEKRI-ERSHAD, S. Texture image analysis and texture classification methods—a review. **arXiv preprint arXiv:1904.06554**, 2019.
- AZEVEDO, E.; CONCI, A. **Computação gráfica: teoria e prática**. 1. ed. Rio de Janeiro: GEN LTC, 2003. v. 1.
- BALBO, J. T. **Pavimentação asfáltica**. 1. ed. Rio de Janeiro: [s.n.], 2007. v. 1. 560 p.
- BARMPOUTIS, P. *et al.* Wood species recognition through multidimensional texture analysis. **Computers and electronics in agriculture**, v. 144, p. 241–248, 2018.
- BARROS, L. G. **Impacto da análise da nitidez em métodos de classificação de imagens de madeira**. 69 p. Dissertação (Mestrado em Computação Aplicada) — Universidade Estadual de Ponta Grossa, Ponta Grossa, 2013. Disponível em <http://tede2.uepg.br>. Acesso em: 2 dez. 2020.
- BARTLEY, F. G. *et al.* **Clay mineralogy of modified marginal aggregates**. [S.l.: s.n.], 2007.
- BERNUCCI, L. B. *et al.* **Pavimentação asfáltica: formação básica para engenheiros**. [S.l.]: Petrobras; ABEDA, 2008.
- BRASIL. Microesferas de vidro retrorrefletivas para sinalização. **Norma rodoviária. IPR**, 2000. Disponível em www.gov.br/dner. Acesso em 4 nov. 2020.
- BREIMAN, L. *et al.* **Classification and regression trees**. 1. ed. [S.l.]: Routledge, 2017.
- CAI-XIANG, Y.; SHU-BO, Q. Image retrieval algorithm based on texture and color features. In: **2009 WASE International Conference on Information Engineering**. Taiwan: [s.n.], 2009. v. 1, p. 125–128.
- CALDAS, E. A. **Avaliação de metodologias de aquisição de imagens para fins de análise de qualidade de sementes de milho**. 65 p. Dissertação (Mestrado em Computação Aplicada) — Universidade Estadual de Ponta Grossa, Ponta Grossa, 2014. Disponível em <http://tede2.uepg.br>. Acesso em 2 dez. 2020.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Art 2-a: An adaptive resonance algorithm for rapid category learning and recognition. **Neural networks**, v. 4, n. 4, p. 493–504, 1991.

CERVANTES, J. *et al.* Data selection based on decision tree for svm classification on large data sets. **Applied Soft Computing**, v. 37, p. 787–798, 2015.

CHAI, H. Y. *et al.* Gray-level co-occurrence matrix bone fracture detection. **WSEAS Transactions on Systems**, v. 10, n. 1, p. 7–16, 2011.

CHEN, K.-H. *et al.* Applying particle swarm optimization-based decision tree classifier for cancer classification on gene expression data. **Applied Soft Computing**, v. 24, p. 773–780, 2014.

CONAB. **Acompanhamento da safra brasileira de grãos, sexto levantamento 2021**. 2021. Disponível em <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em 11 dez. 2021.

DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. **The Journal of Machine Learning Research**, v. 7, p. 1–30, 2006.

EMBRAPA. **VISÃO 2030. O Futuro da Agricultura Brasileira**. 2020. 9 p. Disponível em <https://www.embrapa.br/visao/o-futuro-da-agricultura-brasileira>. Acesso em 25 jun. 2021.

FORMOSO, M. L. Some topics on geochemistry of weathering: a review. **Anais da Academia Brasileira de Ciências**, v. 78, p. 809–820, 2006.

GADELMAWLA, E. A vision system for surface roughness characterization using the gray level co-occurrence matrix. **NDT & e International**, v. 37, n. 7, p. 577–588, 2004.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. [S.l.]: Pearson Educación, 2009.

GOUVEIA, L. *et al.* Entropy-based approach to analyze and classify mineral aggregates. **Journal of computing in civil engineering**, v. 25, n. 1, p. 75–84, 2011.

GOUVEIA, L. T. **Contribuições ao estudo da influência de propriedades de agregados no comportamento de misturas asfálticas densas**. 340 p. Tese (Doutorado em Engenharia Civil) — Universidade de São Paulo, São Paulo, 2006. Disponível em <http://teses.usp.br>. Acesso em 3 mar. 2021.

GOUVEIA, L. T. *et al.* Supervised classification of basaltic aggregate particles based on texture properties. **Journal of computing in civil engineering**, American Society of Civil Engineers, v. 27, n. 2, p. 177–182, 2013.

GOUVEIA, L. T. *et al.* Esqueletização multiescala para análise de forma de agregados. **Transportes**, v. 23, n. 2, p. 14–21, 2015.

GRANIK, M.; MESYURA, V. Fake news detection using naive bayes classifier. In: **2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKR-CON)**. Ucrania: [s.n.], 2017. v. 1, p. 900–903.

HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, IEEE, v. 67, n. 5, p. 786–804, 1979.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. **IEEE Transactions on systems, man, and cybernetics**, IEEE, n. 6, p. 610–621, 1973.

HARALICK, R. M.; SHAPIRO, L. G. **Computer and robot vision**. [S.l.]: Addison-wesley Reading, 1992. v. 1.

HIREMATH, P. S.; BHUSNURMATH, R. A. Multiresolution ldbp descriptors for texture classification using anisotropic diffusion with an application to wood texture analysis. **Pattern Recognition Letters**, v. 89, p. 8–17, 2017.

ITO, R. H.; KIM, H. Y.; SALCEDO, W. J. Classificação de texturas invariante a rotação usando matriz de co-ocorrência. In: **8th International Information and Telecommunication Technologies Symposium**. São Paulo: [s.n.], 2009. p. 1–6.

JENA, B.; MOHANTY, A.; MOHANTY, S. K. Gender recognition of speech signal using knn and svm. **Available at SSRN 3769786**, 2021.

KARU, K.; JAIN, A. K. Fingerprint classification. **Pattern recognition**, v. 29, n. 3, p. 389–404, 1996.

KASEKO, M. S.; RITCHIE, S. G. A neural network-based methodology for pavement crack detection and classification. **Transportation Research Part C: Emerging Technologies**, v. 1, n. 4, p. 275–291, 1993.

KHALID, S.; KHALIL, T.; NASREEN, S. A survey of feature selection and feature extraction techniques in machine learning. In: **2014 Science and Information Conference**. London: [s.n.], 2014. v. 1, p. 372–378.

LEWIS, D. D.; GALE, W. A. A sequential algorithm for training text classifiers. In: **SI-GIR'94**. Murray Hill: [s.n.], 1994. p. 3–12.

MANGULKAR, M. N.; GHOSH, S.; JAMKAR, S. S. Estimation of aggregate characteristics using digital image processing. In: **International Conference on Reliability, Risk Maintenance and Engineering Management**. Singapore: [s.n.], 2019. p. 6–12.

MARTINS EDSON APARECIDO, G. L. T.; SENGER, L. J. Assessing the weathering of basaltic aggregates using image texture analysis. **Iberoamerican Journal of Applied Computing**, v. 10, n. 1, 2020.

MICHAEL, H. L. Highway planning. **Highway Engineering Handbook**, KB Woods, Editor-in-Chief, McGraw-Hill, Inc., New York, 1960.

MOYA, L. *et al.* 3d gray level co-occurrence matrix and its application to identifying collapsed buildings. **ISPRS journal of photogrammetry and remote sensing**, v. 149, p. 14–28, 2019.

NEGRI, T. T. **Descritores locais de textura para classificação de imagens coloridas sob variação de iluminação**. 100 p. Tese (Doutorado em Engenharia elétrica) — Universidade de São Paulo, São Paulo, 2017. Disponível em <http://teses.usp.br>. Acesso em 7 jan. 2021.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern recognition**, v. 29, n. 1, p. 51–59, 1996.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on pattern analysis and machine intelligence**, v. 24, n. 7, p. 971–987, 2002.

OLIVEIRA, L. *et al.* Extração de características de forma utilizando matriz de co-ocorrência e atributos de haralick. In: **Workshop de Visão Computacional (WVC). Programa de Pós-graduação em Ciência e Tecnologia de Sementes, Universidade Federal de Pelotas, Pelotas**. Rio Grande do Sul: [s.n.], 2012.

OLIVEIRA, W. E. B. de *et al.* Classificacao de padroes utilizando descritores de textura. **Simpósio de Mecânica Computacional e Encontro Mineiro de Modelagem Computacional**, 2014.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. São Paulo: Thomson Learning, 2008.

PETRUCCI, E. G. R.; PAULON, V. A. **Concreto de cimento Portland**. 1. ed. São Paulo: Globo, 1993.

PINEDA, J. O. d. C. *et al.* **A entropia segundo Claude Shannon: o desenvolvimento do conceito fundamental da teoria da informação**. 126 p. Dissertação (Mestrado em História da Ciência), 2006. Disponível em <https://tede.pucsp.br>. Acesso em 28 set. 2020.

POHLERT, T. The pairwise multiple comparison of mean ranks package (pmcmr). **R package**, v. 27, n. 2019, p. 9, 2014.

RAJINIKANTH, V.; COUCEIRO, M. Rgb histogram based color image segmentation using firefly algorithm. **Procedia Computer Science**, v. 46, p. 1449–1457, 2015.

RAMALHO, G. L. B. **Análise de imagens por meio da matriz de interdependência e da transformação estrutural multiescala**. 186 p. Tese (Doutorado em Engenharia de Teleinformática) — Universidade Federal do Ceará, Fortaleza, 2013.

RAVI, V.; PRADEEPKUMAR, D.; DEB, K. Financial time series prediction using hybrids of chaos theory, multi-layer perceptron and multi-objective evolutionary algorithms. **Swarm and Evolutionary Computation**, v. 36, p. 136–149, 2017.

SANTOS, A. M. **Investigando a combinação de técnicas de aprendizado semissupervisionado e classificação hierárquica multirrótulo**. 214 p. Tese (Doutorado em Ciência em Computação), Natal, 2012. Disponível em <https://repositorio.ufrn.br>. Acesso em 25 out. 2020.

SHANNON, C. E. A mathematical theory of communication. **The Bell system technical journal**, v. 27, n. 3, p. 379–423, 1948.

SHORTEN, C.; KHOSHGOFTAAR, T. M. on image data augmentation for deep learning. **Journal of Big Data**, v. 6, n. 1, p. 1–48, 2019.

TAYLOR, L.; NITSCHKE, G. Improving deep learning using generic data augmentation. **arXiv preprint arXiv:1708.06020**, Bangalore, 2017.

TAYLOR, L.; NITSCHKE, G. Improving deep learning with generic data augmentation. In: IEEE. **2018 IEEE Symposium Series on Computational Intelligence (SSCI)**. Bangalore, 2018. p. 1542–1547.

VALVERDE, F. M. Agregados para construção civil. **Balço mineral brasileiro**, v. 2001, 2001.

VÁZQUEZ, M. A. *et al.* Digital image processing of weathered stone caused by efflorescences: A tool for mapping and evaluation of stone decay. **Construction and Building Materials**, v. 25, n. 4, p. 1603–1611, 2011.

VIJAYALAKSHMI, B.; MOHAN, V. Kernel-based pso and frvm: An automatic plant leaf type detection using texture, shape, and color features. **Computers and Electronics in Agriculture**, v. 125, p. 99–112, 2016.

WU, Y.; PARKER, F.; KANDHAL, P. S. Aggregate toughness/abrasion resistance and durability/soundness tests related to asphalt concrete performance in pavements. **Transportation Research Record**, v. 1638, n. 1, p. 85–93, 1998.

ZHU, C.; BICHOT, C.-E.; CHEN, L. Multi-scale color local binary patterns for visual object classes recognition. In: **2010 20th International Conference on Pattern Recognition**. Istanbul: [s.n.], 2010. p. 3065–3068.

APÊNDICE A – ANÁLISES ESTATÍSTICAS - GRUPO A

Tabela A1 – Resultado de Nemenyi - Basalto - KNN

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,02077	0,02077	0,02077	0,9	0,02077	0,02077	0,02077	0,02077	0,02077	0,02077	0,02077	0,02077	0,02077	0,02077	0,02077	0,9
C2			0,9	0,9	0,001	0,001	0,001	0,9	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,9
C3				0,9	0,00406	0,00406	0,00406	0,9	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,9
C4					0,01178	0,01178	0,01178	0,9	0,01178	0,01178	0,01178	0,01178	0,01178	0,01178	0,01178	0,01178	0,01178	0,01178	0,01178	0,9
C5						0,9	0,9	0,13441824	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C6							0,9	0,13441824	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C7								0,13441824	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C8									0,13442	0,13442	0,13442	0,13442	0,13442	0,13442	0,13442	0,13442	0,13442	0,13442	0,13442	0,9
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,33238
C14															0,9	0,9	0,9	0,9	0,9	0,33238
C15																0,9	0,9	0,9	0,9	0,33238
C16																	0,9	0,9	0,9	0,33238
C17																		0,9	0,9	0,33238
C18																			0,9	0,33238
C19																				0,33238
C20																				


 Não apresenta diferença estatística
 há diferença estatística

Tabela A2 – Teste de Nemenyi - Basalto - NB

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1	0,9	0,9	0,9	0,9	0,001	0,001	0,9	0,9	0,001	0,12748	0,0486	0,00945	0,04572	0,61159	0,71138	0,86108	0,001	0,001	0,001	0,9	
C2	0,9	0,88603010	0,9	0,001	0,001	0,47333	0,9	0,001	0,01362	0,00375	0,00346	0,17381	0,00346	0,24976	0,40297	0,001	0,001	0,001	0,001	0,9	
C3	0,9	0,9	0,001	0,001	0,62406	0,9	0,001	0,03113	0,00945	0,0014	0,00877	0,29568	0,40297	0,56169	0,001	0,001	0,001	0,001	0,001	0,9	
C4	0,9	0,02723	0,10978	0,9	0,9	0,9	0,9	0,03549	0,9	0,76128	0,45977	0,74881	0,9	0,9	0,9	0,0014	0,0014	0,0014	0,001	0,9	
C5	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,48652	0,37414	0,22917	0,9	0,9	0,9	0,0023	
C6	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,77376	0,67396	0,52427	0,9	0,9	0,9	0,01362	
C7	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,01809	0,01809	0,01178	0,9
C8	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,001	0,37414	0,18154	0,0486	0,17381	0,9	0,9	0,9	0,9	0,001	0,001	0,001	0,9	
C9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,53674	0,43174	0,27224	0,9	0,9	0,9	0,00319	
C10	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,52427	0,52427	0,44589	0,56169
C11	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,73633	0,73633	0,66149	0,33238
C12	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,10978
C13	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,74881	0,74881	0,67396	0,31964
C14	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,0875	0,0875	0,06227	0,9
C15	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,05503	0,05503	0,03786	0,9
C16	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,02545	0,02545	0,01687	0,9
C17	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,001
C18	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,001
C19	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,001
C20	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,001

 Não apresenta diferença estatística
 há diferença estatística

Tabela A3 – Teste de Nemenyi - Basalto - DT

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1	0,9	0,9	0,9	0,001	0,001	0,134418237	0,9	0,001	0,001	0,001	0,066176425	0,773758412	0,001	0,092476848	0,736332713	0,002714271	0,018091055	0,0003751946	0,9	0,9	
C2		0,9	0,9	0,001	0,001	0,070265439	0,9	0,001	0,001	0,031125651	0,624064281	0,001	0,045722381	0,586637988	0,001	0,007548254	0,001396604	0,9	0,9	0,9	
C3			0,9	0,001	0,001	0,014633509	0,9	0,001	0,001	0,005556427	0,30762103	0,001	0,008770213	0,272238745	0,001	0,001078791	0,001	0,9	0,9	0,9	
C4				0,001	0,001	0,003461893	0,636538711	0,9	0,003751946	0,009447869	0,008770213	0,473328047	0,9	0,027228762	0,549216347	0,9	0,058559275	0,2191166	0,074540048	0,9	0,9
C5					0,9	0,723859894	0,001078791	0,9	0,9	0,9	0,886030103	0,109775782	0,9	0,9	0,81118341	0,127476763	0,9	0,9	0,9	0,9	0,001
C6						0,9	0,006482138	0,9	0,9	0,9	0,9	0,30762103	0,9	0,9	0,9	0,34599727	0,9	0,9	0,9	0,9	0,002303341
C7							0,736332713	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,574166303
C8								0,006997462	0,016865316	0,015713556	0,574166303	0,9	0,045722381	0,649010503	0,9	0,092476848	0,30762103	0,116053364	0,9	0,9	
C9									0,9	0,9	0,9	0,319640604	0,9	0,9	0,359939874	0,9	0,9	0,9	0,9	0,9	0,002503537
C10										0,9	0,9	0,486519503	0,9	0,9	0,524265279	0,9	0,9	0,9	0,9	0,9	0,006482138
C11											0,9	0,9	0,473328047	0,9	0,511791273	0,9	0,9	0,9	0,9	0,9	0,006004119
C12												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,402966263
C13													0,673961057	0,9	0,9	0,823655707	0,9	0,873553644	0,9	0,9	0,9
C14														0,9	0,711384289	0,9	0,9	0,9	0,9	0,9	0,019392671
C15															0,9	0,9	0,9	0,9	0,9	0,9	0,486519503
C16																0,861081594	0,9	0,9	0,9	0,9	0,9
C17																	0,9	0,9	0,9	0,9	0,042969932
C18																					0,9
C19																					0,173814414
C20																					0,055034533


 Não apresenta diferença estatística
 há diferença estatística

Tabela A4 – Teste de Nemenyi - Basalto - MLP

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1	0,9	0,9	0,9	0,9	0,15733	0,79871	0,88603	0,9	0,9	0,9	0,15733	0,23899	0,9	0,15733	0,24976	0,9	0,15733	0,15733	0,15733	0,86108
C2		0,9	0,9	0,9	0,001	0,00945	0,9	0,40297	0,346	0,82366	0,001	0,001	0,9	0,001	0,001	0,9	0,001	0,001	0,001	0,9
C3			0,9	0,9	0,01939	0,346	0,9	0,9	0,9	0,9	0,01939	0,03549	0,9	0,01939	0,03786	0,9	0,01939	0,01939	0,01939	0,9
C4				0,9	0,00406	0,13442	0,9	0,9	0,88603	0,9	0,00406	0,00814	0,9	0,00406	0,00877	0,9	0,00406	0,00406	0,00406	0,9
C5					0,9	0,9	0,001	0,72386	0,77376	0,29568	0,9	0,9	0,00195	0,9	0,9	0,001	0,9	0,9	0,9	0,001
C6						0,00475	0,9	0,9	0,9	0,9	0,9	0,9	0,0836	0,9	0,9	0,01362	0,9	0,9	0,9	0,00406
C7							0,28386	0,23899	0,71138	0,001	0,001	0,001	0,9	0,001	0,001	0,9	0,001	0,001	0,001	0,9
C8								0,9	0,9	0,9	0,72386	0,83613	0,82366	0,72386	0,8486	0,47333	0,72386	0,72386	0,72386	0,26086
C9									0,9	0,9	0,77376	0,88603	0,77376	0,77376	0,8985	0,41741	0,77376	0,77376	0,77376	0,21912
C10										0,29568	0,41741	0,41741	0,9	0,29568	0,43174	0,88603	0,29568	0,29568	0,29568	0,68644
C11											0,9	0,9	0,00195	0,9	0,9	0,001	0,9	0,9	0,9	0,001
C12												0,00406	0,00406	0,9	0,9	0,001	0,9	0,9	0,9	0,001
C13														0,00195	0,00439	0,9	0,00195	0,00195	0,00195	0,9
C14															0,9	0,001	0,9	0,9	0,9	0,001
C15																0,001	0,9	0,9	0,9	0,001
C16																	0,001	0,001	0,001	0,9
C17																		0,9	0,9	0,001
C18																			0,9	0,001
C19																				0,001
C20																				

 Não apresenta diferença estatística
 há diferença estatística

Tabela A5 – Teste de Nemenyi - Basalto - RF

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,001397	0,001397	0,001397	0,9	0,001397	0,001397	0,003752	0,9	0,9	0,001397	0,219117	0,536741	0,001397	0,001397	0,001397	0,9
C2			0,9	0,9	0,001	0,001	0,001	0,9	0,001	0,001	0,001	0,599113	0,611589	0,001	0,016865	0,083597	0,001	0,001	0,001	0,9
C3				0,9	0,001	0,001	0,001	0,9	0,001	0,001	0,001	0,72386	0,736333	0,001	0,033244	0,141747	0,001	0,001	0,001	0,9
C4					0,015714	0,015714	0,015714	0,9	0,015714	0,015714	0,035487	0,9	0,9	0,015714	0,611589	0,9	0,015714	0,015714	0,015714	0,9
C5						0,9	0,9	0,058559	0,9	0,9	0,9	0,332385	0,319641	0,9	0,9	0,9	0,9	0,9	0,9	0,001651
C6							0,9	0,058559	0,9	0,9	0,9	0,332385	0,319641	0,9	0,9	0,9	0,9	0,9	0,9	0,001651
C7								0,058559	0,9	0,9	0,9	0,332385	0,319641	0,9	0,9	0,9	0,9	0,9	0,9	0,001651
C8									0,058559	0,058559	0,116053	0,9	0,9	0,058559	0,861082	0,9	0,058559	0,058559	0,058559	0,9
C9										0,9	0,9	0,332385	0,319641	0,9	0,9	0,9	0,9	0,9	0,9	0,001651
C10											0,9	0,332385	0,319641	0,9	0,9	0,9	0,9	0,9	0,9	0,001651
C11												0,499313	0,48652	0,9	0,9	0,9	0,9	0,9	0,9	0,004394
C12													0,9	0,332385	0,9	0,9	0,332385	0,332385	0,332385	0,9
C13															0,9	0,9	0,319641	0,319641	0,319641	0,9
C14																0,9	0,9	0,9	0,9	0,001651
C15																	0,9	0,9	0,9	0,238995
C16																		0,9	0,9	0,561691
C17																			0,9	0,001651
C18																			0,9	0,001651
C19																				0,001651
C20																				

 Não apresenta diferença estatística
 há diferença estatística

Tabela A6 – Resultado do teste de Nemenyi - Granito - KNN

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,01939	0,01939	0,24976	0,9	0,01939	0,01939	0,01939	0,01939	0,01939	0,01939	0,01939	0,24976	0,01939	0,01939	0,01939	0,9
C2			0,9	0,9	0,11605	0,11605	0,62406	0,9	0,11605	0,11605	0,11605	0,11605	0,11605	0,11605	0,11605	0,62406	0,11605	0,11605	0,11605	0,9
C3				0,9	0,00406	0,00406	0,0875	0,74881	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,00406	0,0875	0,00406	0,00406	0,00406	0,9
C4					0,001	0,001	0,02545	0,49931	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,02545	0,001	0,001	0,001	0,9
C5						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C6							0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C7								0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,0836
C8									0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,73633
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C14															0,9	0,9	0,9	0,9	0,9	0,00375
C15																0,9	0,9	0,9	0,9	0,00375
C16																	0,9	0,9	0,9	0,0836
C17																		0,9	0,9	0,00375
C18																			0,9	0,00375
C19																				0,00375
C20																				



 Não apresenta diferença estatística
 Há diferença estatística

Tabela A7 – Resultado do teste de Nemenyi - Granito - NB

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,51179	0,9	0,9	0,83613	0,9	0,64901	0,01687	0,9	0,00346	0,03324	0,9	0,9	0,9	0,9	0,9	0,67396	0,67396	0,67396	0,83613
C2			0,346	0,09797	0,9	0,9	0,001	0,9	0,62406	0,00346	0,9	0,9	0,15733	0,9	0,45977	0,00152	0,9	0,9	0,9	0,001
C3				0,9	0,68644	0,9	0,79871	0,007	0,9	0,00128	0,01463	0,9	0,9	0,9	0,9	0,9	0,52427	0,52427	0,52427	0,9
C4					0,33238	0,9	0,9	0,001	0,9	0,001	0,0018	0,9	0,72386	0,9	0,9	0,9	0,19046	0,19046	0,19046	0,9
C5						0,9	0,00128	0,9	0,9	0,0238	0,79871	0,9	0,45977	0,9	0,78623	0,01178	0,9	0,9	0,9	0,00439
C6							0,20929	0,14175	0,9	0,68644	0,04297	0,22917	0,9	0,9	0,9	0,56169	0,9	0,9	0,9	0,38851
C7								0,001	0,53674	0,9	0,001	0,001	0,9	0,01362	0,69891	0,9	0,001	0,001	0,001	0,9
C8									0,03113	0,001	0,9	0,9	0,00165	0,68644	0,01267	0,001	0,9	0,9	0,9	0,001
C9										0,9	0,007	0,05856	0,9	0,9	0,9	0,88603	0,78623	0,78623	0,78623	0,72386
C10											0,001	0,001	0,9	0,14175	0,9	0,9	0,00945	0,00945	0,00945	0,9
C11												0,9	0,001	0,41741	0,0025	0,001	0,9	0,9	0,9	0,001
C12													0,00375	0,81118	0,02545	0,001	0,9	0,9	0,9	0,001
C13														0,83613	0,9	0,9	0,28386	0,28386	0,28386	0,9
C14															0,9	0,0836	0,9	0,9	0,9	0,03786
C15																0,9	0,62406	0,62406	0,62406	0,88603
C16																	0,00439	0,00439	0,00439	0,9
C17																		0,9	0,9	0,00152
C18																			0,9	0,00152
C19																				0,00152
C20																				

 Não apresenta diferença estatística
 Há diferença estatística

Tabela A8 – Resultado do teste de Nemenyi - Granito - DT

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1	0,9	0,9	0,9	0,9	0,001	0,09797	0,29568	0,001	0,001	0,001	0,01809	0,01017	0,01178	0,05856	0,9	0,69891	0,8985	0,67396	0,27224	0,9
C2			0,9	0,9	0,01267	0,54922	0,83613	0,01017	0,00271	0,00271	0,20929	0,14175	0,15733	0,43174	0,9	0,9	0,9	0,9	0,81118	0,9
C3				0,9	0,001	0,01463	0,06618	0,001	0,001	0,001	0,0018	0,001	0,00108	0,00755	0,56169	0,30762	0,52427	0,28386	0,05856	0,9
C4					0,001	0,01178	0,05503	0,001	0,001	0,001	0,0014	0,001	0,001	0,006	0,52427	0,27224	0,48652	0,24976	0,0486	0,9
C5						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,37414	0,62406	0,41741	0,64901	0,9	0,001
C6							0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,01571
C7								0,9	0,76128	0,76128	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,07027
C8									0,9	0,9	0,9	0,9	0,9	0,9	0,33238	0,58664	0,37414	0,61159	0,9	0,001
C9										0,9	0,9	0,9	0,9	0,9	0,15733	0,35994	0,18154	0,38851	0,78623	0,001
C10											0,9	0,9	0,9	0,9	0,15733	0,35994	0,18154	0,38851	0,78623	0,001
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00195
C12													0,9	0,9	0,87355	0,9	0,9	0,9	0,9	0,001
C13														0,9	0,8985	0,9	0,9	0,9	0,9	0,00118
C14															0,9	0,9	0,9	0,9	0,9	0,00814
C15																0,9	0,9	0,9	0,9	0,57417
C16																	0,9	0,9	0,9	0,31964
C17																		0,9	0,9	0,53674
C18																			0,9	0,29568
C19																				0,06227
C20																				


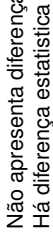
 Não apresenta diferença estatística
 Há diferença estatística

Tabela A9 – Resultado do teste de Nemenyi - Granito - MLP

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1	0,9	0,9	0,9	0,9	0,27224	0,44589	0,9	0,10978	0,9	0,9	0,03786	0,07027	0,86108	0,06227	0,9	0,9	0,18154	0,40297	0,07027	0,9	
C2			0,9	0,9	0,8486	0,9	0,53674	0,61159	0,9	0,9	0,37414	0,51179	0,28386	0,48652	0,9	0,40297	0,73633	0,9	0,51179	0,9	
C3				0,9	0,26086	0,43174	0,9	0,10374	0,9	0,9	0,03549	0,06618	0,87355	0,05856	0,9	0,9	0,17381	0,38851	0,06618	0,9	
C4					0,01571	0,03786	0,9	0,00375	0,9	0,9	0,001	0,00195	0,9	0,00165	0,28386	0,9	0,00814	0,03113	0,00195	0,9	
C5						0,9	0,001	0,9	0,72386	0,01095	0,9	0,9	0,001	0,9	0,9	0,001	0,9	0,9	0,9	0,03324	
C6							0,00195	0,9	0,88603	0,02723	0,9	0,9	0,001	0,9	0,9	0,001	0,9	0,9	0,9	0,07454	
C7								0,001	0,66149	0,9	0,001	0,001	0,9	0,001	0,03324	0,9	0,001	0,00152	0,001	0,9	
C8									0,48652	0,0025	0,9	0,9	0,001	0,9	0,9	0,001	0,9	0,9	0,9	0,00877	
C9										0,9	0,24976	0,37414	0,41741	0,346	0,9	0,53674	0,61159	0,8486	0,37414	0,9	
C10											0,001	0,00128	0,9	0,00108	0,22917	0,9	0,00556	0,02224	0,00128	0,9	
C11												0,9	0,001	0,9	0,9	0,001	0,9	0,9	0,9	0,00212	
C12													0,001	0,9	0,9	0,001	0,9	0,9	0,9	0,00475	
C13														0,001	0,00877	0,9	0,001	0,001	0,001	0,9	
C14															0,9	0,001	0,9	0,9	0,9	0,00406	
C15																0,01687	0,9	0,9	0,9	0,43174	
C16																	0,001	0,001	0,001	0,9	
C17																		0,9	0,9	0,01809	
C18																				0,9	0,06227
C19																					0,00475
C20																					



 Não apresenta diferença estatística
 Há diferença estatística

Tabela A10 – Resultado do teste de Nemenyi - Granito - RF

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,64901	0,9	0,9	0,9	0,9	0,9	0,01362	0,9	0,9	0,00346	0,007	0,00195	0,9	0,9	0,13442	0,9	0,9	0,9	0,9
C2			0,0238	0,03549	0,02545	0,01809	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,54922	0,10978	0,87355
C3				0,9	0,9	0,9	0,19972	0,001	0,45977	0,24976	0,001	0,001	0,001	0,67396	0,62406	0,001	0,9	0,9	0,9	0,9
C4					0,9	0,9	0,26086	0,001	0,53674	0,31964	0,001	0,001	0,001	0,74881	0,69891	0,00128	0,9	0,9	0,9	0,9
C5						0,9	0,20929	0,001	0,47333	0,26086	0,001	0,001	0,001	0,68644	0,63654	0,001	0,9	0,9	0,9	0,9
C6							0,16546	0,001	0,40297	0,20929	0,001	0,001	0,001	0,62406	0,57417	0,001	0,9	0,9	0,9	0,9
C7								0,74881	0,9	0,9	0,52427	0,63654	0,43174	0,9	0,9	0,9	0,9	0,9	0,9	0,51179
C8									0,48652	0,68644	0,9	0,9	0,9	0,26086	0,30762	0,9	0,06618	0,00755	0,001	0,04572
C9										0,9	0,24976	0,35994	0,18154	0,9	0,9	0,9	0,9	0,9	0,77376	0,9
C10											0,45977	0,57417	0,35994	0,9	0,9	0,9	0,9	0,9	0,57417	0,9
C11												0,9	0,9	0,10978	0,13442	0,9	0,02077	0,0018	0,001	0,01362
C12													0,9	0,17381	0,20929	0,9	0,03786	0,00375	0,001	0,02545
C13														0,07454	0,09248	0,9	0,01267	0,001	0,001	0,00814
C14															0,9	0,73633	0,9	0,9	0,9	0,9
C15																0,78623	0,9	0,9	0,9	0,9
C16																	0,38851	0,0875	0,006	0,30762
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				

 Não apresenta diferença estatística
 Há diferença estatística

Tabela A11 – Resultado do teste Nemenyi - basalto + granito - KNN

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,01362	0,01362	0,01362	0,9	0,01362	0,01362	0,01362	0,01362	0,01362	0,01362	0,01362	0,01362	0,01362	0,01362	0,01362	0,9
C2			0,9	0,9	0,03113	0,03113	0,03113	0,9	0,03113	0,03113	0,03113	0,03113	0,03113	0,03113	0,03113	0,03113	0,03113	0,03113	0,03113	0,9
C3				0,9	0,00271	0,00271	0,00271	0,9	0,00271	0,00271	0,00271	0,00271	0,00271	0,00271	0,00271	0,00271	0,00271	0,00271	0,00271	0,9
C4					0,001	0,001	0,001	0,9	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,9
C5						0,9	0,9	0,30762	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C6							0,9	0,30762	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C7								0,30762	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C8									0,30762	0,30762	0,30762	0,30762	0,30762	0,30762	0,30762	0,30762	0,30762	0,30762	0,30762	0,9
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,14945
C14															0,9	0,9	0,9	0,9	0,9	0,14945
C15																0,9	0,9	0,9	0,9	0,14945
C16																	0,9	0,9	0,9	0,14945
C17																		0,9	0,9	0,14945
C18																			0,9	0,14945
C19																				0,14945
C20																				

 Não apresenta diferença estatística
 há diferença estatística

Tabela A12 – Resultado do teste Nemenyi - basalto + granito - NB

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1		0,9	0,9	0,9	0,001	0,27224	0,45977	0,9	0,0875	0,03786	0,37414	0,09248	0,001	0,57417	0,9	0,04572	0,001	0,001	0,001	0,001	0,9
C2			0,9	0,9	0,001	0,01939	0,0486	0,9	0,00346	0,00108	0,03324	0,00375	0,001	0,0836	0,48652	0,0014	0,001	0,001	0,001	0,001	0,9
C3				0,9	0,001	0,07899	0,16546	0,9	0,01809	0,00648	0,12254	0,01939	0,001	0,24976	0,76128	0,00814	0,001	0,001	0,001	0,001	0,9
C4					0,00475	0,8486	0,9	0,9	0,56169	0,37414	0,9	0,57417	0,001	0,9	0,9	0,41741	0,001	0,001	0,001	0,001	0,9
C5						0,83613	0,66149	0,00319	0,9	0,9	0,73633	0,9	0,9	0,54922	0,10978	0,9	0,9	0,9	0,9	0,9	0,001
C6							0,9	0,78623	0,9	0,9	0,9	0,9	0,49931	0,9	0,9	0,9	0,43174	0,49931	0,54922	0,54922	0,33238
C7								0,9	0,9	0,9	0,9	0,9	0,30762	0,9	0,9	0,9	0,24976	0,30762	0,35994	0,35994	0,52427
C8									0,49931	0,30762	0,88603	0,51179	0,001	0,9	0,9	0,346	0,001	0,001	0,001	0,001	0,9
C9										0,9	0,9	0,9	0,78623	0,9	0,9	0,9	0,72386	0,78623	0,83613	0,83613	0,11605
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,8985	0,9	0,9	0,9	0,05169
C11												0,9	0,38851	0,9	0,9	0,9	0,31964	0,38851	0,44589	0,44589	0,44589
C12													0,77376	0,9	0,9	0,9	0,71138	0,77376	0,82366	0,82366	0,12254
C13														0,20929	0,02077	0,9	0,9	0,9	0,9	0,9	0,001
C14															0,9	0,9	0,16546	0,20929	0,24976	0,24976	0,63654
C15																0,9	0,01463	0,02077	0,02723	0,02723	0,9
C16																	0,86108	0,9	0,9	0,9	0,06227
C17																		0,9	0,9	0,9	0,001
C18																			0,9	0,001	0,001
C19																					0,001
C20																					

 Não apresenta diferença estatística
 há diferença estatística

Tabela A13 – Resultado do teste Nemenyi - basalto + granito - DT

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,001	0,00648	0,001	0,9	0,001	0,001	0,001	0,001	0,001	0,10374	0,22917	0,14945	0,00319	0,00514	0,38851	0,9
C2			0,9	0,9	0,00375	0,05503	0,00346	0,9	0,001	0,001	0,001	0,001	0,01017	0,41741	0,62406	0,51179	0,03113	0,04572	0,78623	0,9
C3				0,9	0,001	0,00346	0,001	0,9	0,001	0,001	0,001	0,001	0,001	0,06618	0,15733	0,09797	0,00165	0,00271	0,28386	0,9
C4					0,01017	0,11605	0,00945	0,9	0,001	0,001	0,001	0,00212	0,02545	0,58664	0,78623	0,67396	0,07027	0,09797	0,9	0,9
C5						0,9	0,9	0,14175	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,86108	0,03786
C6							0,9	0,58664	0,82366	0,9	0,79871	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,28386
C7								0,13442	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,8486	0,03549
C8									0,001	0,00556	0,001	0,04572	0,26086	0,9	0,9	0,9	0,47333	0,54922	0,9	0,9
C9										0,9	0,9	0,9	0,9	0,28386	0,13442	0,20929	0,9	0,86108	0,06618	0,001
C10											0,9	0,9	0,9	0,59911	0,38851	0,51179	0,9	0,9	0,22917	0,001
C11												0,9	0,9	0,26086	0,12254	0,19046	0,9	0,83613	0,05856	0,001
C12													0,9	0,9	0,77376	0,88603	0,9	0,9	0,61159	0,00945
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,0836
C14															0,9	0,9	0,9	0,9	0,9	0,82366
C15																0,9	0,9	0,9	0,9	0,9
C16																	0,9	0,9	0,9	0,9
C17																		0,9	0,9	0,19046
C18																			0,9	0,24976
C19																				0,9
C20																				



 Não apresenta diferença estatística
 Há diferença estatística

Tabela A14 – Resultado do teste Nemenyi - basalto + granito - MLP

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,14175	0,77376	0,9	0,9	0,9	0,9	0,01809	0,44589	0,9	0,01809	0,9	0,9	0,01809	0,01809	0,01809	0,9
C2			0,9	0,9	0,07027	0,61159	0,9	0,9	0,9	0,9	0,007	0,27224	0,9	0,007	0,76128	0,9	0,007	0,007	0,007	0,9
C3				0,9	0,001	0,05169	0,9	0,38851	0,56169	0,9	0,001	0,00877	0,9	0,001	0,10374	0,9	0,001	0,001	0,001	0,9
C4					0,06618	0,59911	0,9	0,9	0,9	0,9	0,00648	0,26086	0,9	0,00648	0,74881	0,9	0,00648	0,00648	0,00648	0,9
C5						0,9	0,001	0,9	0,88603	0,27224	0,9	0,9	0,001	0,9	0,9	0,00195	0,9	0,9	0,9	0,0018
C6							0,00945	0,9	0,9	0,9	0,9	0,9	0,03786	0,9	0,9	0,0836	0,9	0,9	0,9	0,07899
C7								0,12748	0,23899	0,8486	0,001	0,00118	0,9	0,001	0,02224	0,9	0,001	0,001	0,001	0,9
C8									0,9	0,9	0,62406	0,9	0,31964	0,62406	0,9	0,49931	0,62406	0,62406	0,62406	0,48652
C9										0,9	0,45977	0,9	0,49931	0,45977	0,9	0,66149	0,45977	0,45977	0,45977	0,64901
C10											0,04572	0,62406	0,9	0,04572	0,9	0,9	0,04572	0,04572	0,04572	0,9
C11												0,9	0,001	0,9	0,9	0,001	0,9	0,9	0,9	0,001
C12													0,006	0,9	0,9	0,01571	0,9	0,9	0,9	0,01463
C13														0,001	0,07899	0,9	0,001	0,001	0,001	0,9
C14															0,9	0,001	0,9	0,9	0,9	0,001
C15																0,15733	0,9	0,9	0,9	0,14945
C16																	0,001	0,001	0,001	0,9
C17																		0,9	0,9	0,001
C18																			0,9	0,001
C19																				0,001
C20																				





 Não apresenta diferença estatística
 Há diferença estatística

Tabela A15 – Resultado do teste Nemenyi - basalto + granito - RF

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,001	0,001	0,001	0,9	0,001	0,001	0,00271	0,81118	0,57417	0,001	0,86108	0,30762	0,001	0,001	0,001	0,9
C2			0,9	0,9	0,001	0,001	0,00165	0,9	0,001	0,001	0,00556	0,9	0,68644	0,001	0,9	0,43174	0,001	0,001	0,001	0,9
C3				0,9	0,001	0,001	0,001	0,9	0,001	0,001	0,001	0,51179	0,26086	0,001	0,56169	0,09797	0,001	0,001	0,001	0,9
C4					0,00514	0,00514	0,04297	0,9	0,00514	0,00514	0,10374	0,9	0,9	0,01178	0,9	0,9	0,00514	0,00514	0,00514	0,9
C5						0,9	0,9	0,02545	0,9	0,9	0,9	0,21912	0,45977	0,9	0,18154	0,71138	0,9	0,9	0,9	0,0014
C6							0,9	0,02545	0,9	0,9	0,9	0,21912	0,45977	0,9	0,18154	0,71138	0,9	0,9	0,9	0,0014
C7								0,14945	0,9	0,9	0,9	0,59911	0,83613	0,9	0,54922	0,9	0,9	0,9	0,9	0,01463
C8									0,02545	0,02545	0,29568	0,9	0,9	0,05169	0,9	0,9	0,02545	0,02545	0,02545	0,9
C9										0,9	0,9	0,21912	0,45977	0,9	0,18154	0,71138	0,9	0,9	0,9	0,0014
C10											0,9	0,21912	0,45977	0,9	0,18154	0,71138	0,9	0,9	0,9	0,0014
C11												0,78623	0,9	0,9	0,73633	0,9	0,9	0,9	0,9	0,04035
C12													0,9	0,346	0,9	0,9	0,21912	0,21912	0,21912	0,9
C13														0,59911	0,9	0,9	0,45977	0,45977	0,45977	0,9
C14															0,29568	0,8486	0,9	0,9	0,9	0,00346
C15																0,9	0,18154	0,18154	0,18154	0,9
C16																	0,71138	0,71138	0,71138	0,78623
C17																		0,9	0,9	0,0014
C18																			0,9	0,0014
C19																				0,0014
C20																				

 Não apresenta diferença estatística
 Há diferença estatística

APÊNDICE B – ANÁLISES ESTATÍSTICAS - GRUPO B

Tabela B16 – Resultado de Nemenyi - Basalto - KNN

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,28386	0,00195	0,001	0,9	0,43174	0,01178	0,28386	0,00195	0,001	0,28386	0,00195	0,001	0,28386	0,28386	0,28386	0,88603
C2			0,9	0,9	0,31964	0,0025	0,001	0,9	0,47333	0,01463	0,31964	0,0025	0,001	0,31964	0,0025	0,001	0,31964	0,31964	0,31964	0,9
C3				0,9	0,28386	0,00195	0,001	0,9	0,43174	0,01178	0,28386	0,00195	0,001	0,28386	0,00195	0,001	0,28386	0,28386	0,28386	0,88603
C4					0,24976	0,00152	0,001	0,9	0,38851	0,00945	0,24976	0,00152	0,001	0,24976	0,00152	0,001	0,24976	0,24976	0,24976	0,8486
C5						0,9	0,43174	0,18154	0,9	0,9	0,9	0,9	0,43174	0,9	0,9	0,43174	0,9	0,9	0,9	0,9
C6							0,9	0,001	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,66149
C7								0,001	0,28386	0,9	0,43174	0,9	0,9	0,43174	0,9	0,9	0,43174	0,43174	0,43174	0,04297
C8									0,29568	0,00556	0,18154	0,001	0,001	0,18154	0,001	0,001	0,18154	0,18154	0,18154	0,76128
C9										0,9	0,9	0,9	0,28386	0,9	0,9	0,28386	0,9	0,9	0,9	0,9
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C11												0,9	0,43174	0,9	0,9	0,43174	0,9	0,9	0,9	0,9
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,66149
C13														0,43174	0,9	0,9	0,43174	0,43174	0,43174	0,04297
C14															0,9	0,43174	0,9	0,9	0,9	0,9
C15																0,9	0,9	0,9	0,9	0,66149
C16																	0,43174	0,43174	0,43174	0,04297
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				

 Não há diferença estatísticas
 Há diferença estatística

Tabela B17 – Teste de Nemenyi - Basalto - NB

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1		0,9	0,9	0,9	0,00475	0,00514	0,001	0,9	0,04572	0,88603	0,00475	0,00514	0,9	0,00475	0,00514	0,9	0,00475	0,00475	0,00475	0,00475	0,44589
C2			0,9	0,9	0,00755	0,00814	0,001	0,9	0,06618	0,9	0,00755	0,00814	0,9	0,00755	0,00814	0,9	0,00755	0,00755	0,00755	0,00755	0,52427
C3				0,9	0,01095	0,01178	0,001	0,9	0,0875	0,9	0,01095	0,01178	0,9	0,01095	0,01178	0,9	0,01095	0,01095	0,01095	0,01095	0,58664
C4					0,01571	0,01687	0,001	0,9	0,11605	0,9	0,01571	0,01687	0,9	0,01571	0,01687	0,9	0,01571	0,01571	0,01571	0,01571	0,64901
C5						0,9	0,83613	0,00475	0,9	0,79871	0,9	0,9	0,01362	0,9	0,9	0,06227	0,9	0,9	0,9	0,9	0,9
C6							0,82366	0,00514	0,9	0,81118	0,9	0,9	0,01463	0,9	0,9	0,06618	0,9	0,9	0,9	0,9	0,9
C7								0,001	0,43174	0,00346	0,83613	0,82366	0,001	0,83613	0,82366	0,001	0,83613	0,83613	0,83613	0,83613	0,04297
C8									0,04572	0,88603	0,00475	0,00514	0,9	0,00475	0,00514	0,9	0,00475	0,00475	0,00475	0,00475	0,44589
C9										0,9	0,9	0,9	0,10374	0,9	0,9	0,30762	0,9	0,9	0,9	0,9	0,9
C10											0,79871	0,81118	0,9	0,79871	0,81118	0,9	0,79871	0,79871	0,79871	0,79871	0,9
C11												0,9	0,01362	0,9	0,9	0,06227	0,9	0,9	0,9	0,9	0,9
C12													0,01463	0,9	0,9	0,06618	0,9	0,9	0,9	0,9	0,9
C13														0,01362	0,01463	0,9	0,01362	0,01362	0,01362	0,01362	0,62406
C14															0,9	0,06227	0,9	0,9	0,9	0,9	0,9
C15																0,06618	0,9	0,9	0,9	0,9	0,9
C16																	0,06227	0,06227	0,06227	0,06227	0,9
C17																		0,9	0,9	0,9	0,9
C18																				0,9	0,9
C19																					0,9
C20																					

 Não há diferença estatísticas
 Há diferença estatística

Tabela B18 – Teste de Nemenyi - Basalto - DT

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,01362	0,05503	0,001	0,9	0,007	0,04035	0,9	0,9	0,9	0,9	0,9	0,9	0,12254	0,10374	0,03549	0,0025
C2			0,9	0,9	0,01463	0,05856	0,001	0,9	0,00755	0,04297	0,9	0,9	0,9	0,9	0,9	0,9	0,12748	0,10978	0,03786	0,00271
C3				0,9	0,00271	0,01362	0,001	0,9	0,00128	0,00945	0,9	0,9	0,9	0,9	0,9	0,9	0,03549	0,02912	0,00814	0,001
C4					0,01571	0,06227	0,001	0,9	0,00814	0,04572	0,9	0,9	0,9	0,9	0,9	0,9	0,13442	0,11605	0,04035	0,00295
C5						0,9	0,9	0,01362	0,9	0,9	0,03549	0,02077	0,01571	0,02545	0,03324	0,01017	0,9	0,9	0,9	0,9
C6							0,9	0,05503	0,9	0,9	0,12254	0,07899	0,06227	0,09248	0,11605	0,04297	0,9	0,9	0,9	0,9
C7								0,001	0,9	0,9	0,00152	0,001	0,001	0,001	0,0014	0,001	0,9	0,9	0,9	0,9
C8									0,007	0,04035	0,9	0,9	0,9	0,9	0,9	0,9	0,12254	0,10374	0,03549	0,0025
C9										0,9	0,01939	0,01095	0,00814	0,01362	0,01809	0,00514	0,9	0,9	0,9	0,9
C10											0,09248	0,05856	0,04572	0,07027	0,0875	0,03113	0,9	0,9	0,9	0,9
C11												0,9	0,9	0,9	0,9	0,9	0,23899	0,20929	0,0836	0,00755
C12													0,9	0,9	0,9	0,9	0,16546	0,14175	0,05169	0,00406
C13														0,9	0,9	0,9	0,13442	0,11605	0,04035	0,00295
C14															0,9	0,9	0,19046	0,16546	0,06227	0,00514
C15																0,9	0,22917	0,19972	0,07899	0,007
C16																	0,09797	0,0836	0,02723	0,0018
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				



 Não há diferença estatísticas
 Há diferença estatística

Tabela B19 – Teste de Nemenyi - Basalto - MLP

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,001	0,00439	0,001	0,9	0,10978	0,73633	0,05503	0,37414	0,001	0,00514	0,01095	0,001	0,04035	0,31964	0,00439	0,26086
C2			0,9	0,9	0,001	0,01939	0,001	0,9	0,28386	0,9	0,16546	0,63654	0,00212	0,02224	0,04297	0,001	0,12748	0,58664	0,01939	0,52427
C3				0,9	0,001	0,00212	0,001	0,9	0,06618	0,62406	0,03113	0,26086	0,001	0,0025	0,00556	0,001	0,02224	0,21912	0,00212	0,17381
C4					0,001	0,01362	0,001	0,9	0,22917	0,9	0,12748	0,57417	0,0014	0,01571	0,03113	0,001	0,09797	0,52427	0,01362	0,45977
C5						0,9	0,9	0,001	0,9	0,43174	0,9	0,78623	0,9	0,9	0,9	0,9	0,9	0,83613	0,9	0,8985
C6							0,9	0,0018	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C7								0,001	0,9	0,37414	0,9	0,73633	0,9	0,9	0,9	0,9	0,9	0,78623	0,9	0,8486
C8									0,05856	0,59911	0,02723	0,23899	0,001	0,00212	0,00475	0,001	0,01939	0,19972	0,0018	0,15733
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C10											0,9	0,9	0,57417	0,9	0,9	0,346	0,9	0,9	0,9	0,9
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C12													0,9	0,9	0,9	0,71138	0,9	0,9	0,9	0,9
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,9
C14															0,9	0,9	0,9	0,9	0,9	0,9
C15																0,9	0,9	0,9	0,9	0,9
C16																	0,9	0,76128	0,9	0,82366
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				


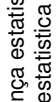
 Não há diferença estatísticas
 Há diferença estatística

Tabela B20 – Teste de Nemenyi - Basalto - RF

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1	0,9	0,9	0,9	0,01463	0,02723	0,001	0,9	0,01809	0,02077	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,19046	0,07027	0,15733	0,001
C2		0,9	0,9	0,06227	0,10374	0,00118	0,9	0,07454	0,0836	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,45977	0,21912	0,40297	0,00152
C3			0,9	0,06227	0,10374	0,00118	0,9	0,07454	0,0836	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,45977	0,21912	0,40297	0,00152
C4				0,03113	0,05503	0,001	0,9	0,03786	0,04297	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,30762	0,12748	0,26086	0,001
C5				0,9	0,03113	0,9	0,9	0,03113	0,9	0,00648	0,00648	0,00648	0,00648	0,01463	0,01463	0,03113	0,9	0,9	0,9	0,9
C6					0,9	0,05503	0,9	0,9	0,9	0,01267	0,01267	0,01267	0,01267	0,02723	0,02723	0,05503	0,9	0,9	0,9	0,9
C7						0,9	0,001	0,9	0,9	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,9	0,9	0,9	0,9
C8								0,9	0,03786	0,04297	0,9	0,9	0,9	0,9	0,9	0,9	0,30762	0,12748	0,26086	0,001
C9									0,9	0,00814	0,00814	0,00814	0,00814	0,01809	0,01809	0,03786	0,9	0,9	0,9	0,9
C10										0,00945	0,00945	0,00945	0,00945	0,02077	0,02077	0,04297	0,9	0,9	0,9	0,9
C11											0,9	0,9	0,9	0,9	0,9	0,9	0,10978	0,03549	0,0875	0,001
C12												0,9	0,9	0,9	0,9	0,9	0,10978	0,03549	0,0875	0,001
C13														0,9	0,9	0,9	0,10978	0,03549	0,0875	0,001
C14															0,9	0,9	0,19046	0,07027	0,15733	0,001
C15																0,9	0,19046	0,07027	0,15733	0,001
C16																	0,30762	0,12748	0,26086	0,001
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				

 Não há diferença estatísticas
 Há diferença estatística

Tabela B21 – Resultado do teste de Nemenyi - Granito - KNN

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20		
C1		0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,07899	
C2			0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00556	
C3				0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,71138
C4					0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,20929
C5						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C6							0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C7								0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,02224
C8									0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00556
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C13														0	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,02224
C14															0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C15																0,9	0,9	0,9	0,9	0,9	0,9	0,47333
C16																	0,9	0,9	0,9	0,9	0,9	0,02224
C17																		0,9	0,9	0,9	0,9	0,47333
C18																			0,9	0,9	0,9	0,47333
C19																						0,47333
C20																						

 Não há diferença estatísticas
 Há diferença estatística

Tabela B22 – Resultado do teste de Nemenyi - Granito - NB

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1		0,9	0,9	0,9	0,9	0,04297	0,9	0,9	0,9	0,9	0,9	0,05503	0,9	0,9	0,04297	0,9	0,9	0,9	0,9	0,9	0,23899
C2			0,9	0,9	0,72386	0,00195	0,9	0,9	0,9	0,9	0,72386	0,00271	0,9	0,72386	0,00195	0,9	0,72386	0,72386	0,72386	0,72386	0,02224
C3				0,9	0,9	0,09797	0,9	0,9	0,9	0,9	0,9	0,12254	0,9	0,9	0,09797	0,9	0,9	0,9	0,9	0,9	0,41741
C4					0,9	0,02077	0,9	0,9	0,9	0,9	0,9	0,02723	0,9	0,9	0,02077	0,9	0,9	0,9	0,9	0,9	0,14175
C5						0,82366	0,86108	0,48652	0,9	0,47333	0,9	0,87355	0,43174	0,9	0,82366	0,67396	0,9	0,9	0,9	0,9	0,9
C6							0,00475	0,001	0,02545	0,001	0,82366	0,9	0,001	0,82366	0,9	0,0014	0,82366	0,82366	0,82366	0,82366	0,9
C7								0,9	0,9	0,9	0,86108	0,00648	0,9	0,86108	0,00475	0,9	0,86108	0,86108	0,86108	0,86108	0,04572
C8									0,9	0,9	0,48652	0,001	0,9	0,48652	0,001	0,9	0,48652	0,48652	0,48652	0,48652	0,00556
C9										0,9	0,9	0,03324	0,9	0,9	0,02545	0,9	0,9	0,9	0,9	0,9	0,16546
C10											0,47333	0,001	0,9	0,47333	0,001	0,9	0,47333	0,47333	0,47333	0,47333	0,00514
C11												0,87355	0,43174	0,9	0,82366	0,67396	0,9	0,9	0,9	0,9	0,9
C12													0,001	0,87355	0,9	0,00195	0,87355	0,87355	0,87355	0,87355	0,9
C13														0,43174	0,001	0,9	0,43174	0,43174	0,43174	0,43174	0,00406
C14															0,82366	0,67396	0,9	0,9	0,9	0,9	0,9
C15																0,0014	0,82366	0,82366	0,82366	0,82366	0,9
C16																	0,67396	0,67396	0,67396	0,67396	0,01687
C17																		0,9	0,9	0,9	0,9
C18																					0,9
C19																					0,9
C20																					

 Não há diferença estatísticas
 Há diferença estatística

Tabela B23 – Resultado do teste de Nemenyi - Granito - DT

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20	
C1	0,9	0,86108	0,9	0,9	0,45977	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,12254	
C2			0,86108	0,9	0,9	0,45977	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,12254	
C3				0,9	0,9	0,37414	0,63654	0,37414	0,61159	0,63654	0,63654	0,63654	0,61159	0,83613	0,9	0,37414	0,9	0,9	0,9	0,9	0,9
C4					0,9	0,66149	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,26086
C5						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,61159
C6							0,0836	0,22917	0,0836	0,20929	0,22917	0,22917	0,20929	0,43174	0,66149	0,0836	0,9	0,9	0,9	0,9	0,9
C7								0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,86108	0,86108	0,86108	0,86108	0,01095
C8									0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,04297
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,86108	0,86108	0,86108	0,86108	0,01095
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,03786
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,04297
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,04297
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,03786
C14															0,9	0,9	0,9	0,9	0,9	0,9	0,10978
C15																0,9	0,9	0,9	0,9	0,9	0,26086
C16																	0,86108	0,86108	0,86108	0,86108	0,01095
C17																		0,9	0,9	0,9	0,9
C18																				0,9	0,9
C19																					0,9
C20																					

 Não há diferença estatísticas
 Há diferença estatística

Tabela B24 – Resultado do teste de Nemenyi - Granito - MLP

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,9	0,9	0,07899	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,64901	0,9	0,9	0,9	0,00346
C2			0,9	0,9	0,9	0,9	0,346	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,03324
C3				0,9	0,9	0,9	0,30762	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,02723
C4					0,9	0,9	0,19046	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,86108	0,9	0,9	0,9	0,01267
C5						0,9	0,8486	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,27224
C6							0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,64901
C7								0,07899	0,62406	0,9	0,346	0,8985	0,9	0,45977	0,346	0,9	0,30762	0,9	0,9	0,9
C8									0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,64901	0,9	0,9	0,9	0,00346
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,11605
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,51179
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,03324
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,31964
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,37414
C14															0,9	0,9	0,9	0,9	0,9	0,05503
C15																0,9	0,9	0,9	0,9	0,03324
C16																	0,9	0,9	0,9	0,9
C17																		0,9	0,9	0,02723
C18																			0,9	0,61159
C19																				0,49931
C20																				

 Não há diferença estatísticas
 Há diferença estatística

Tabela B25 – Resultado do teste de Nemenyi - Granito - RF

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20		
C1		0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,02723	
C2			0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,01571	
C3				0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,48652
C4					0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,49931
C5						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,01178
C6							0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,0875
C7								0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,05503
C8									0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,12748
C9										0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,05503
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,05503
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,12748
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,04297
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,05503
C14															0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,00375
C15																0,9	0,9	0,9	0,9	0,9	0,9	0,0875
C16																	0,9	0,9	0,9	0,9	0,9	0,05503
C17																		0,9	0,9	0,9	0,9	0,04297
C18																			0,9	0,9	0,9	0,04297
C19																					0,9	0,04297
C20																						

 Não há diferença estatísticas
 Há diferença estatística

Tabela B26 – Resultado do teste Nemenyi - basalto + granito - KNN

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1	0,9	0,9	0,9	0,12748	0,00128	0,00128	0,001	0,9	0,82366	0,01463	0,12748	0,00128	0,001	0,12748	0,00128	0,001	0,12748	0,12748	0,12748	0,64901
C2			0,9	0,9	0,05169	0,001	0,001	0,9	0,62406	0,00439	0,05169	0,001	0,001	0,05169	0,001	0,001	0,05169	0,05169	0,05169	0,44589
C3				0,9	0,24976	0,00406	0,0025	0,9	0,9	0,03786	0,24976	0,00406	0,0025	0,24976	0,00406	0,0025	0,24976	0,24976	0,24976	0,82366
C4					0,15733	0,0018	0,00108	0,9	0,87355	0,01939	0,15733	0,0018	0,00108	0,15733	0,0018	0,00108	0,15733	0,15733	0,15733	0,69891
C5						0,9	0,9	0,01809	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C6							0,9	0,001	0,66149	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,83613
C7								0,001	0,58664	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,76128
C8									0,41741	0,00118	0,01809	0,001	0,001	0,01809	0,001	0,001	0,01809	0,01809	0,01809	0,23899
C9										0,9	0,9	0,66149	0,58664	0,9	0,66149	0,58664	0,9	0,9	0,9	0,9
C10											0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C11												0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C12													0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,83613
C13														0,9	0,9	0,9	0,9	0,9	0,9	0,76128
C14															0,9	0,9	0,9	0,9	0,9	0,9
C15																0,9	0,9	0,9	0,9	0,83613
C16																	0,9	0,9	0,9	0,76128
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				

 Não há diferença estatísticas
 Há diferença estatística

Tabela B27 – Resultado do teste Nemenyi - basalto + granito - NB

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1		0,9	0,9	0,9	0,01571	0,001	0,00212	0,9	0,12748	0,69891	0,01571	0,001	0,9	0,01571	0,001	0,9	0,00814	0,00814	0,00814	0,001
C2			0,9	0,9	0,19046	0,001	0,04572	0,9	0,61159	0,9	0,19046	0,001	0,9	0,19046	0,001	0,9	0,12254	0,12254	0,12254	0,00814
C3				0,9	0,02545	0,001	0,00375	0,9	0,18154	0,78623	0,02545	0,001	0,9	0,02545	0,001	0,9	0,01362	0,01362	0,01362	0,001
C4					0,68644	0,0014	0,346	0,82366	0,9	0,9	0,68644	0,0025	0,9	0,68644	0,0025	0,9	0,57417	0,57417	0,57417	0,10978
C5						0,81118	0,9	0,00152	0,9	0,9	0,9	0,8985	0,28386	0,9	0,8985	0,28386	0,9	0,9	0,9	0,9
C6							0,9	0,001	0,37414	0,02912	0,81118	0,9	0,001	0,81118	0,9	0,001	0,9	0,9	0,9	0,9
C7								0,001	0,9	0,86108	0,9	0,9	0,07899	0,9	0,9	0,07899	0,9	0,9	0,9	0,9
C8									0,02077	0,30762	0,00152	0,001	0,9	0,00152	0,001	0,9	0,001	0,001	0,001	0,001
C9										0,9	0,9	0,47333	0,72386	0,9	0,47333	0,72386	0,9	0,9	0,9	0,9
C10											0,9	0,04572	0,9	0,9	0,04572	0,9	0,9	0,9	0,9	0,54922
C11												0,8985	0,28386	0,9	0,8985	0,28386	0,9	0,9	0,9	0,9
C12													0,001	0,8985	0,9	0,001	0,9	0,9	0,9	0,9
C13														0,28386	0,001	0,9	0,19046	0,19046	0,19046	0,01571
C14															0,8985	0,28386	0,9	0,9	0,9	0,9
C15																0,001	0,9	0,9	0,9	0,9
C16																	0,19046	0,19046	0,19046	0,01571
C17																		0,9	0,9	0,9
C18																			0,9	0,9
C19																				0,9
C20																				

 Não há diferença estatísticas
 Há diferença estatística

Tabela B28 – Resultado do teste Nemenyi - basalto + granito - DT

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20		
C1		0,83613	0,9	0,9	0,49931	0,9	0,16546	0,9	0,59911	0,9	0,87355	0,9	0,78623	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,15733	
C2			0,9	0,9	0,001	0,00945	0,001	0,01017	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,01939	0,05856	0,0486	0,0486	0,001	
C3				0,9	0,26086	0,73633	0,06227	0,9	0,35994	0,74881	0,9	0,9	0,9	0,9	0,9	0,9	0,86108	0,9	0,9	0,9	0,05856	
C4					0,30762	0,78623	0,07899	0,9	0,41741	0,79871	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,07454
C5						0,9	0,9	0,00439	0,9	0,9	0,001	0,00439	0,001	0,02912	0,04297	0,00118	0,9	0,9	0,9	0,9	0,9	0,9
C6							0,9	0,05856	0,9	0,9	0,01178	0,05856	0,007	0,22917	0,29568	0,02077	0,9	0,9	0,9	0,9	0,9	0,9
C7								0,001	0,9	0,9	0,001	0,001	0,001	0,00375	0,006	0,001	0,9	0,9	0,9	0,9	0,9	0,9
C8									0,00814	0,06227	0,9	0,9	0,9	0,9	0,9	0,9	0,10374	0,23899	0,20929	0,20929	0,001	0,001
C9										0,9	0,00118	0,00814	0,001	0,0486	0,07027	0,0023	0,9	0,9	0,9	0,9	0,9	0,9
C10											0,01267	0,06227	0,00755	0,23899	0,30762	0,02224	0,9	0,9	0,9	0,9	0,9	0,9
C11												0,9	0,9	0,9	0,9	0,9	0,0238	0,07027	0,05856	0,05856	0,001	0,001
C12													0,9	0,9	0,9	0,9	0,10374	0,23899	0,20929	0,20929	0,001	0,001
C13														0,9	0,9	0,9	0,01463	0,04572	0,03786	0,03786	0,001	0,001
C14															0,9	0,9	0,346	0,57417	0,53674	0,53674	0,00346	0,00346
C15																0,9	0,43174	0,64901	0,61159	0,61159	0,00556	0,00556
C16																	0,04035	0,10978	0,09248	0,09248	0,001	0,001
C17																		0,9	0,9	0,9	0,9	0,9
C18																					0,9	0,9
C19																						0,9
C20																						

■ Não há diferença estatísticas

■ Há diferença estatística


Tabela B29 – Resultado do teste Nemenyi - basalto + granito - MLP

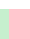
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1	0,9	0,9	0,9	0,9	0,07899	0,07454	0,001	0,9	0,9	0,9	0,04572	0,01178	0,001	0,03113	0,02912	0,001	0,09248	0,09797	0,00648	0,73633
C2		0,9	0,9	0,9	0,01809	0,01687	0,001	0,9	0,9	0,78623	0,00945	0,00195	0,001	0,006	0,00556	0,001	0,02224	0,0238	0,001	0,44589
C3			0,9	0,9	0,07027	0,06618	0,001	0,9	0,9	0,9	0,04035	0,01017	0,001	0,02723	0,02545	0,001	0,0836	0,0875	0,00556	0,71138
C4				0,9	0,31964	0,30762	0,001	0,9	0,9	0,9	0,21912	0,07899	0,001	0,16546	0,15733	0,001	0,35994	0,37414	0,0486	0,9
C5					0,9	0,82366	0,00945	0,82366	0,9	0,9	0,9	0,9	0,82366	0,9	0,9	0,40297	0,9	0,9	0,9	0,9
C6						0,83613	0,00877	0,81118	0,9	0,9	0,9	0,9	0,83613	0,9	0,9	0,41741	0,9	0,9	0,9	0,9
C7						0,9	0,001	0,00375	0,02224	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,78623	0,77376	0,9	0,11605
C8						0,9	0,67396	0,00475	0,001	0,00295	0,00271	0,001	0,001	0,00295	0,00271	0,001	0,01178	0,01267	0,001	0,31964
C9						0,9	0,71138	0,45977	0,00375	0,63654	0,62406	0,00375	0,00375	0,63654	0,62406	0,001	0,86108	0,87355	0,346	0,9
C10						0,9	0,76128	0,02224	0,9	0,9	0,9	0,9	0,02224	0,9	0,9	0,0018	0,9	0,9	0,66149	0,9
C11						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,52427	0,9	0,9	0,9	0,9
C12						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,77376	0,9	0,9	0,9	0,9
C13						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,78623	0,77376	0,9	0,11605
C14						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,59911	0,9	0,9	0,9	0,9
C15						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,61159	0,9	0,9	0,9	0,9
C16						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,35994	0,346	0,87355	0,01463	0,9
C17						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C18						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C19						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
C20						0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9

 Não há diferença estatísticas
 Há diferença estatística

Tabela B30 – Resultado do teste Nemenyi - basalto + granito - RF

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18	C19	C20
C1	0,9	0,9	0,9	0,73633	0,61159	0,00877	0,9	0,24976	0,51179	0,9	0,9	0,9	0,87355	0,9	0,9	0,9	0,62406	0,9	0,68644	0,00514
C2		0,574166303	0,79871	0,02077	0,01017	0,001	0,9	0,00108	0,00556	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,01095	0,07899	0,01571	0,001
C3			0,9	0,9	0,9	0,19046	0,76128	0,88603	0,9	0,67396	0,67396	0,23899	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,13442
C4				0,9	0,9	0,07454	0,9	0,66149	0,9	0,8985	0,8985	0,47333	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,0486
C5					0,9	0,9	0,05503	0,9	0,9	0,03549	0,03549	0,00295	0,13442	0,43174	0,17381	0,9	0,9	0,9	0,9	0,9
C6						0,9	0,02912	0,9	0,9	0,01809	0,01809	0,00128	0,07899	0,29568	0,10374	0,9	0,9	0,9	0,9	0,9
C7							0,001	0,9	0,9	0,001	0,001	0,001	0,001	0,00128	0,001	0,9	0,78623	0,9	0,9	0,9
C8								0,00375	0,01687	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,03113	0,17381	0,04297	0,001
C9									0,9	0,00212	0,00212	0,001	0,01267	0,07454	0,01809	0,9	0,9	0,9	0,9	0,9
C10										0,01017	0,01017	0,001	0,0486	0,20929	0,06618	0,9	0,9	0,9	0,9	0,9
C11											0,9	0,9	0,9	0,9	0,9	0,9	0,01939	0,12254	0,02723	0,001
C12												0,9	0,9	0,9	0,9	0,9	0,01939	0,12254	0,02723	0,001
C13													0,9	0,9	0,9	0,9	0,0014	0,01463	0,00212	0,001
C14														0,9	0,9	0,9	0,0836	0,346	0,10978	0,001
C15															0,9	0,9	0,30762	0,69891	0,37414	0,001
C16																	0,10978	0,41741	0,14175	0,001
C17																		0,9	0,9	0,9
C18																			0,9	0,69891
C19																				0,9
C20																				

 Não há diferença estatísticas

 Há diferença estatística

APÊNDICE C – CÓDIGO-FONTE

A seguir, o código fonte que foi desenvolvido para realizar a extração de características das imagens de agregados.

Código C.1 – Código fonte de extração de características

```
1
2
3 # Codigo desenvolvido por Rogerio Kraft Kohler
4
5 #Importando bibliotecas
6
7 import cv2
8 import io
9 import pandas as pd
10 import math
11 import os
12 import numpy as np
13 import scipy as sc
14 from skimage import feature
15 from imutils import paths
16 from keras.preprocessing import image
17 from skimage.feature import local_binary_pattern
18 from scipy.stats import entropy
19 from matplotlib import pyplot as plt
20 from sklearn.metrics.cluster import entropy
21 from skimage.feature import greycomatrix, greycoprops
22 from skimage.measure import shannon_entropy
23
24 # Carregando as imagens
25
26 file_list = []
27 file_list.append(os.listdir(r"/home/rogerio/Mestrado/Laboratorio/
    imagem_original/basalto_original/0"))
28 file_list.append(os.listdir(r"/home/rogerio/Mestrado/Laboratorio/
    imagem_original/basalto_original/1"))
29 file_list.append(os.listdir(r"/home/rogerio/Mestrado/Laboratorio/
    imagem_original/basalto_original/2"))
30 file_list.append(os.listdir(r"/home/rogerio/Mestrado/Laboratorio/
    imagem_original/basalto_original/3"))
31
32 # Lista de classes
33
34 class_names = ['0', '1', '2', '3']
35
36 # definindo as listas, dicionarios, variaveis, etc
37
38 color = ('b', 'g', 'r')
39
```

```
40 classe_y = []
41 nome_arquivo = []
42 dados = []
43 hist = [[], [], []]
44 hist_aux = [[], [], []]
45 freq0 = []
46 freq1 = []
47 freq2 = []
48
49 histograma0 = {}
50 histograma1 = {}
51 histograma2 = {}
52 histograma_cinza = {}
53 matriz_r = []
54 contador_aux = []
55 entropia_colorida = []
56
57 raio = 1
58 pontos = 8
59 cont = {}
60 pmaximo = (2**pontos)
61 value = 0
62 lbp_default = {}
63 lbp_uniform = {}
64 matrix = {}
65
66 # Caminho para pasta original
67
68 path = '/home/rogerio/Mestrado/Laboratorio/imagem_original/basalto_original
69 /'
70
71 # Funcao para mostrar histograma rgb
72
73 def histograma(imagem):
74     for i, col in enumerate(color):
75         histr = cv2.calcHist([imagem], [i], None, [256], [0, 256])
76         plt.plot(histr, color=col)
77         plt.xlim([0, 256])
78     plt.show()
79     cv2.waitKey(0)
80     cv2.destroyAllWindows()
81
82 # percorre as imagens e realiza os calculos.
83
84 for classes_files, classe in zip(file_list, range(len(file_list))):
85     print('Classe: ', class_names[classe])
86     print('Total de arquivos da classe: ', len(classes_files))
```

```
86     for i in range(0, len(classes_files)):
87         name = str(path) + str(class_names[classe]) + str('/') + str(
classes_files[i])
88         imagem = cv2.imread(name)
89         arq = str(classes_files[i])
90         imagem = cv2.cvtColor(imagem, cv2.COLOR_BGR2RGB)
91         imagem_lbp = imagem_lbp_u = imagem_lbp_nova = imagem_lbp_u_nova =
imagem_g_lcm = imagem_cinza = imagem
92
93         pixel_depth = 256
94         altura, largura, canais = imagem.shape
95         tamanho = (altura * largura)
96
97         # Criando os vetores
98         hist.clear()
99         freq0.clear()
100        freq1.clear()
101        freq2.clear()
102        hist = [[], [], []]
103        hist_cinza = []
104        histograma_cinza = []
105
106        #####
107
108        # Imagem cinza
109
110        imagem_cinza = cv2.cvtColor(imagem, cv2.COLOR_BGR2GRAY)
111
112        for c in range(0, pixel_depth):
113            hist_cinza.append(0)
114
115
116        # Varrendo a imagem para computar o histograma
117        for a in range(altura):
118            for l in range(largura):
119
120                pixel = imagem_cinza[a, l]
121                hist_cinza[pixel] = hist_cinza[pixel] + 1
122
123        #####
124
125        # Inicializando histograma com zeros
126        for c in range(0, canais):
127            for b in range(0, pixel_depth):
128                hist[c].append(0)
129
130        # Varrendo a imagem para computar o histograma
```

```

131     for a in range(altura):
132         for l in range(largura):
133
134             pixel = imagem[a, l]
135             hist[0][pixel[0]] = hist[0][pixel[0]] + 1
136             hist[1][pixel[1]] = hist[1][pixel[1]] + 1
137             hist[2][pixel[2]] = hist[2][pixel[2]] + 1
138
139     # Calcula frequencias dos histogramas
140
141     # Calcula frequencia do canal 0
142
143     for f in range(0, len(hist[0])):
144         freq = (hist[0][f] / tamanho)
145         freq0.append(freq)
146
147     # Calcula frequencia do canal 1
148
149     for f in range(0, len(hist[1])):
150         freq = (hist[1][f] / tamanho)
151         freq1.append(freq)
152
153     # Calcula frequencia do canal 2
154
155     for f in range(0, len(hist[2])):
156         freq = (hist[2][f] / tamanho)
157         freq2.append(freq)
158
159     # Calcula frequencia da imagem em tons de cinza
160
161     for f in range(0, len(hist_cinza)):
162         hist_cinza_aux = (hist_cinza[f] / tamanho)
163         histograma_cinza.append(hist_cinza_aux)
164
165     hist_aux = hist.copy()           # histograma
166     frequencia0 = freq0.copy()      # frequencia canal 0
167     frequencia1 = freq1.copy()      # frequencia canal 1
168     frequencia2 = freq2.copy()      # frequencia canal 2
169     frequencia_cinza = histograma_cinza.copy() # frequencia cinza
170
171     #####
172
173     # calculo da entropia
174
175     # ENTROPIA COLORIDA
176
177     entropia_R = shannon_entropy(hist[0])

```



```

178 entropia_G = shannon_entropy(hist[1])
179 entropia_B = shannon_entropy(hist[2])
180
181 #####
182
183 # Iniciando calculo LBP padrao
184
185 # Criando matriz LBP por cor separada
186
187 matriz_r = []
188 for y in range(0, altura):
189     linha_r = []
190     for x in range(0, largura):
191         vermelho = imagem_lbp.item(y, x, 0)
192         verde = imagem_lbp.item(y, x, 1)
193         azul = imagem_lbp.item(y, x, 2)
194         linha_r.append(vermelho)
195     matriz_r.append(linha_r)
196
197 lbp_default.clear()
198 for k in range(0, pmaximo): #iniciando o vetor lbp com zeros
199     lbp_default[k] = 0
200
201 lbp = local_binary_pattern(matriz_r, pontos, raio, 'default')
202 for a in range(0, altura):
203     for l in range(0, largura):
204         value = int(lbp[a, l])
205         lbp_default[value] += 1
206         imagem_lbp_nova[a, l] = (int(value))
207
208 lbp_key = []
209 for i in range(0, pixel_depth):
210     itens = lbp_default.get(i)
211     lbp_key.append(itens)
212
213 histograma_lbp = lbp_key.copy()
214
215 #####
216
217 # Inicio calculo LBPU
218
219 lbp_uniform.clear()
220 for u in range(0, pmaximo): #preenche o vetor com 0
221     lbp_uniform[u] = 0
222
223 lbp_u = local_binary_pattern(matriz_r, pontos, raio, method='
nri_uniform')

```

```

224     for a in range(0, altura):
225         for l in range(0, largura):
226             value = int(lbpu[a][l])
227             lbp_uniform[value] += 1
228             imagem_lbpu_nova[a, l] = (lbpu[a][l])
229
230     lbpu_key = []
231     for u in range(0, pixel_depth):
232         itens = lbp_uniform.get(u)
233         lbpu_key.append(itens)
234
235     histograma_lbpu = lbpu_key.copy()
236
237     #####
238
239     # Grava os dados por experimentos
240
241     # escolhe os dados a serem salvos para cada
242     # experimento (nesse caso, C1).
243     #C1 - Dados do histograma em tons de cinza
244     # Alterar os experimentos de C1 ate C20
245     dados_extraidos = [frequencia_cinza]
246
247     dados_extraidos_aux = []
248     for aux in dados_extraidos:
249         dados_extraidos_aux = np.append(dados_extraidos_aux, np.ravel(
250     aux))
251
252     dados_extraidos = [i for i in dados_extraidos_aux]
253     dados.append(dados_extraidos)
254     classe_y.append(class_names[classe])
255     nome_arquivo.append(arq)
256 # fim dos calculos
257
258
259 # Exporta dados para CSV
260
261 df = pd.DataFrame(dados)
262 df.to_csv('/home/rogerio/Mestrado/Laboratorio/imagem_original/C1/X.csv',
263         sep=',', header=False, index=False)
264
265
266
267
268

```

```
269
270 df = pd.DataFrame(classe_y)
271 df.to_csv('/home/rogerio/Mestrado/Laboratorio/imagem_original/C1/y.csv',
272           sep=',', header=False, index=False)
273
274
275
276 # fim do codigo-fonte
```