

Classificação automática de Rochas Ornamentais utilizando técnicas de Aprendizagem Automática

Um estudo aplicado ao calcário

Automatic classification of ornamental stones using Machine Learning techniques

A study applied to limestone

Marco Tereso

Instituto Superior de Gestão e Administração de Santarém
Santarém, Portugal
marco.tereso@islasantarem.pt

Luís Rato, Teresa Gonçalves

Departamento de Informática da Universidade de Évora
Évora, Portugal
lmr@uevora.pt, tcg@uevora.pt

Resumo — A indústria de extração e transformação de minerais rochosos tem uma enorme importância na balança comercial Portuguesa. O volume de exportações aumenta a cada ano e, para manter estes resultados, é necessário investir na modernização e otimização dos processos de produção, bem como na classificação das matérias-primas. Este estudo tem como finalidade implementar um modelo de classificação de rochas ornamentais através da análise e classificação de imagens, com recursos a algoritmos de aprendizagem automática. O reconhecimento do tipo de pedra, através da captura de imagens e posterior análise algorítmica, permitirá em processos futuros definir escalas de controlo de qualidade, tendo em conta o seu tipo. Este processo permitirá ainda desenvolver modelos capazes de ajudar a diminuir a quantidade de matéria-prima desperdiçada. Este trabalho apresenta os passos realizados para a criação de um modelo de classificação, utilizando um conjunto de 2260 imagens distribuídas por quatro classes, sendo três delas bastante similares ao nível da cor e uma outra com uma tonalidade diferenciada. Neste estudo são analisados os resultados da aplicação de três algoritmos de classificação automática, a forma como os tipos de imagens pode melhorar os resultados e os tempos de execução de algoritmos.

Palavras Chave – rochas ornamentais, aprendizagem automática, classificação de imagens.

Abstract — The industry of extraction and transformation of rock minerals has an enormous importance in the Portuguese trade balance. The export volume increases every year, and to maintain these results it is necessary to invest in the modernization and optimization of production processes, as well as, in the classification of raw materials. This study aims to implement a classification model of ornamental rocks through the analysis and classification of images, using machine learning algorithms. The recognition of the type of stone, through the capture of images and subsequent algorithmic analysis, will allow to define quality control scales in future processes, taking into account the different types of stone. In addition, it will also allow to develop models capable of helping in reducing the amount of raw material wasted. This work presents the steps taken to create a classification model, using a dataset of 2260 images distributed over four classes, three of which are very similar to color level and one with a different

tone. In this study, the results of the application of three automatic classification algorithms are analyzed. In addition, a discussion of how types of images can improve results and the execution times of algorithms are presented.

Keywords – ornamental rocks, machine learning, image classification.

I. INTRODUÇÃO

A indústria de extração e transformação de pedra constitui uma atividade extremamente importante e com um peso significativo ao nível da receita económica nacional. Portugal na sua área geográfica dispõe de cerca de 410 milhões de metros cúbicos de rochas ornamentais, com uma distribuição de 274 milhões referentes a granitos, 76 milhões a calcários, 51 milhões a mármore e 9 milhões a ardósias [1].

As exportações têm aumentado significativamente nos últimos anos. Segundo Miguel Goulão, presidente da Assimagra, associação que representa os Recursos Minerais de Portugal, as empresas portuguesas no ano de 2018, obtiveram um volume de exportação na ordem dos 378 milhões de euros, resultando num aumento de 10,5% em relação ao ano de 2017 [2]. Face aos números apresentados, este é um setor que justifica um investimento na automatização e otimização de processos relevantes para a garantia da qualidade do produto final.

Na indústria da extração e transformação de pedra, seguem-se um conjunto de etapas desde a extração dos blocos provenientes de pedreiras até ao processo de corte, que culmina com o embalamento do produto final. Do conjunto de procedimentos, resultantes desta atividade é importante conhecer cada um dos tipos de pedra, através da análise da sua cor e texturas. Mediante este conhecimento é possível identificar e reconhecer características próprias de cada um destes tipos de materiais, tendo em conta a sua constituição. Cada tipo de pedra pode ser aplicado em obras com características específicas, sendo que, a resistência e constituição dos próprios materiais condiciona a seleção dos mesmos na utilização de diferentes

obras. Esta classificação permitirá a construção de escalas de índice de qualidade, podendo a pedra ser classificada como material de primeira, segunda ou terceira categoria, mediante um conjunto de padrões previamente estabelecidos. O reconhecimento de pedras de forma automática permitirá, em processos futuros, que modelos de aprendizagem automática sejam utilizados para a deteção de defeitos e diminuição do desperdício da matéria-prima.

Este é um trabalho preliminar que tem como finalidade a classificação de defeitos de forma automatizada na indústria da pedra, melhorando um processo que é manual e que requer muito conhecimento. Ajudará, também, na otimização da matéria-prima de modo a diminuir o volume desperdiçado. Nesta primeira fase é importante treinar um modelo de classificação para o reconhecimento dos diferentes tipos de pedra. Posteriormente, o objetivo passa por aplicar modelos de deteção de defeitos nas chapas, através do processamento de imagens. A classificação de defeitos poderá seguir modelos diferentes para cada tipo de pedra.

O objetivo deste estudo é, então, a classificação de pedra, quanto ao seu tipo, de modo automático, a partir da análise e classificação de imagens. As imagens utilizadas neste estudo, foram fornecidas por uma empresa do ramo da extração e transformação de rochas calcárias.

Para o desenvolvimento deste trabalho utilizamos um conjunto com 2260 imagens distribuídas em quatro categorias diferentes, sendo que três dessas categorias são pedras de tonalidades muito semelhantes, o que confere ao estudo uma maior relevância e importância.

Este artigo está estruturado da seguinte forma: a secção II apresenta um enquadramento teórico do problema, o conceito de aprendizagem automática e os três modelos de classificação a utilizar na implementação prática; na secção III é descrito o trabalho desenvolvido no âmbito da implementação prática; a secção IV enumera sucintamente os resultados obtidos e a discussão sobre os mesmos; por fim, a secção V apresenta as conclusões e o trabalho futuro.

II. ENQUADRAMENTO TEÓRICO DO PROBLEMA

Este estudo procura desenvolver um modelo de classificação automática que, através da digitalização da imagem das chapas após o processo de polimento, faça o reconhecimento e a classificação do tipo de pedra em utilização.

Os quatro tipos de pedra são CADOICO (Cadoico Azul Mónica Silva), SBM (Salgueira Branco do Mar), SBR (Salgueira Branco Real) e VMF (Vidraço Moleanos Farpedra), todos exemplares extraídos do Parque Natural da Serra de Aire e Candeeiros (PNSAC), localizado na zona Oeste de Portugal, abrangendo alguns concelhos dos distritos de Leiria e Santarém. Esta zona é conhecida por Maciço Calcário Estremenho [3]. Tendo em conta que os tipos de pedra analisados são extraídas da mesma zona, PNSAC, é natural que alguns tenham aspeto e tonalidades similares. Dos tipos em análise, à exceção do tipo CADOICO, que se difere pela sua tonalidade mais escura, os restantes (SBM, SBR e VMF) têm uma tonalidade muito semelhante, o que torna este estudo mais interessante, tendo em conta um maior grau de dificuldade entre a distinção destes três

tipos, quando comparada com o outro. A Figura 1, ilustra um exemplo de cada um dos tipos de pedra em análise.




Figura 1. Exemplo de cada tipo de pedra em análise

Para proceder à classificação automática dos tipos de pedra através da análise às imagens disponibilizadas, foi necessário proceder à criação de um *dataset*. Neste processo foram realizadas algumas ações para o tratamento das imagens disponibilizadas (os passos serão descritos na secção Implementação Prática).

A. Aprendizagem Automática

A área da Aprendizagem automática pode ser dividida em três sub-áreas: a aprendizagem supervisionada, onde a máquina recebe um conjunto de dados classificados e classifica dados desconhecidos tendo em conta as características que considere discriminantes; a aprendizagem não supervisionada, em que a máquina sem qualquer informação ou classificação, tenta encontrar padrões nos dados; a classificação semi-supervisionada, em que estão disponíveis para a construção do modelo apenas uma parte dos dados rotulados.

Para o problema em análise estamos perante um problema de aprendizagem supervisionada, em que os dados já se encontram classificados (para cada imagem, qual o tipo de pedra a que diz respeito). Na aprendizagem supervisionada existem problemas de regressão e de classificação [4]. Neste caso, estamos perante um problema de classificação, já que a pedra, pertence a um dos quatro valores possíveis.

B. Algoritmos de Aprendizagem Automática

Neste estudo foram testados três algoritmos de classificação distintos: Support Vector Machine (SVM), Naïve Bayes (NB) e Logistic Regression (LR), de modo a analisar os resultados obtidos por cada um deles.

1) Support Vector Machine

O algoritmo SVM é bastante utilizado em problemas de classificação e regressão, nomeadamente em diagnósticos médicos através de reconhecimento de imagens, tomadas de decisão e bioinformática. De uma forma resumida, este algoritmo o modelo é definido através da zona de fronteira que melhor separa dados de diferentes classes (hyperplano). Este algoritmo tem como finalidade identificar o hyperplano ótimo dos dados em análise.

2) Naïve Bayes

O classificador de Naïve Bayes aplica métodos de classificação através de análise probabilística. Este classificador refuta a sua classificação em eventos anteriores para prever a probabilidade em ocorrências futuras [5].

Este classificador é bastante utilizado na classificação de textos, bem como na classificação de mensagem de SPAM. Para além destas aplicações, o Naïve Bayes também se aplica na classificação de imagens, de modo a medir a probabilidade de

identificar objetos numa imagem, tendo por base o seu conhecimento anterior sobre o objeto pretendido.

Este algoritmo constrói uma tabela de probabilidades, definindo, desta forma, a sua tabela de aprendizagem.

3) Logistic Regression

A Regressão Logística (LR) é um método estatístico que tem como objetivo fazer uma análise preditiva através de um conjunto de dados conhecidos [6]. A regressão logística é aplicada em vários campos de ML, nomeadamente para prever os riscos de desenvolver doenças, tais como diabetes ou hipertensão, tendo em conta um conjunto de fatores característicos do paciente (idade, sexo, imc, entre outros) [7]; cálculo de previsão de voto de um determinado eleitor, tendo em conta a sua faixa etária, o sexo e o seu historial de votações [8]; estudos de mercado medindo a aceitação de determinado produto pelo seu público alvo [9]; análise e classificação de imagens [10].

III. IMPLEMENTAÇÃO PRÁTICA

O desenvolvimento prático deste trabalho, contemplou um conjunto de fases, desde o processo de aquisição das imagens até à sua classificação e medição dos resultados obtidos para cada um dos algoritmos analisados.

As imagens foram facultadas por uma empresa de extração e transformação de rochas ornamentais, sediada na zona da Serra de Aire e Candeeiros. Esta empresa encontra-se numa zona em que as suas rochas ornamentais são classificadas por *Limestone* (rochas calcárias). A empresa detém e comercializa diferentes tipos de pedra, de tonalidades, texturas e acabamentos diversificados.

Toda a peça processada pela empresa segue um ciclo comum de transformação. A matéria-prima apresenta-se em blocos com medidas variáveis, mas com um máximo de 3,5 metros de comprimento e 2,5 metros de altura. Estes blocos são transformados em chapas de dimensão variável na sua espessura. Após os vários processos de corte, as chapas dão entrada numa máquina polidora, que tem como finalidade polir uma das superfícies da chapa, de modo a eliminar as marcas resultantes dos processos abrasivos de corte. Após este processo, a chapa é digitalizada por um scanner que reproduz a imagem à medida que a chapa se desloca no tapete, guardando as imagens no computador da própria polidora. Estas imagens são capturadas em esquema de cores RGB e guardadas no formato jpg. Estas imagens ocupam entre 1Mb a 3Mb de espaço em disco, a maioria tem uma dimensão de 3500px por 2500px.

Após a aquisição do conjunto de imagens disponibilizadas, foi necessário fazer a catalogação das amostras quanto ao tipo de pedra. As imagens foram separadas por categorias, com nomenclatura diferenciada, de modo a preparar o processo de treino do algoritmo.

As imagens, agrupadas em quatro classes (CADOICO, SBM, SBR e VMF), num total de 2260 exemplares, contém a representação do tapete de deslocação das chapas na polidora, o que pode originar classificações erradas. Para evitar possíveis falhas de classificação, e tendo em conta a existência de bordas nas imagens, foi necessário proceder à eliminação das margens a preto e, posteriormente, efetuar o recorte da imagem tornar a

matriz de pixéis resultante o mais verídica possível. A Figura 1, ilustra exemplos das imagens disponibilizadas pela empresa, antes do processo de transformação, para o treino do modelo de classificação.

No processo de eliminação de bordas foi criado um script em Python, com recurso à classe Image da biblioteca PIL (versão mais recente da biblioteca Pillow), sendo as margens das imagens eliminadas através do método *crop*.

As imagens resultantes têm dimensões diferentes, o algoritmo desenvolvido tem a capacidade de recortar a imagem, preservando a maior zona de interesse possível.

Após o processo de recorte, as imagens foram guardadas no formato png. Posteriormente procedeu-se à recriação das imagens no formato jpg tendo sido gerado um novo conjunto para a realização posterior de análises comparativas.

A Figura 2, ilustra exemplos das imagens, num formato de mosaico, após a execução dos processos referidos.



Figura 2. Exemplo de imagens após a transformação

Analisando a Figura 2, percebemos que das quatro classes em análise, a classe CADOICO diferencia-se bastante das restantes, em termos de tonalidade de cor. As outras três classes têm cores muito semelhantes, prevendo-se que, os algoritmos tenham uma maior probabilidade de falhar na distinção entre SBM, SBR e VMF.

A Tabela I ilustra a distribuição das imagens do *dataset* pelas quatro classes

TABELA I. DISTRIBUIÇÃO DO Nº DE AMOSTRAS UTILIZADO

Classe	Amostras
CADOICO	495
SBM	837
SBR	306
VMF	622

A segunda fase, teve como objetivo identificar as especificações do *setup* para, posteriormente, criar o modelo de classificação.

Tendo em conta que as amostras disponibilizadas apenas contemplam pedras de textura lisa, no modelo desenvolvido para a classificação das quatro classes, apenas se considerou como *característica* os valores dos pixéis RGB. Os atributos definidos para este modelo foram: nome da imagem; caminho do ficheiro; tamanho da imagem; comprimento e altura. As características das imagens foram extraídas através do modelo, Inception-v3.

Inception-v3, é a terceira versão de uma arquitetura da Google, de alto desempenho. Baseada num estudo publicado por Christian Szegedy e outros autores, intitulado de “Rethinking the Inception Architecture for Computer Vision” [11], é reconhecida por ter um custo computacional associado,

relativamente baixo. A literatura identifica duas medidas principais na medição da precisão, *top-5 error rate* e o *top-1 error rate*. Estas medidas avaliam a precisão dos resultados obtidos, identificando cinco classes possíveis e uma classe possível respetivamente. Esta arquitetura obteve uma taxa de erro de 5,6% no top-5 error rate e de 21,2% para o top-1 error rate. Valores bastante superiores aos registados pelo AlexNet [12], que alcançou uma taxa de erro de 21,2% no top-5 error rate, enquanto que a arquitetura GoogLeNet nas mesmas categorias fixou a sua taxa de erro em 6,67% [13].

O Inception-v3 faz um bom aproveitamento da memória e alivia o processamento dos dados. Treinada no ImageNet, representa as imagens com um vetor numérico com 2048 dimensões.

Para o treino do modelo, foi necessário proceder à divisão do total de amostras em treino e validação.

Existe diferentes métodos de avaliação dos modelos: como, por exemplo, O *holdout* (método que define uma percentagem de dados para treino e o restante para testes, 2/3 para treino e 1/3 para testes, é uma divisão comum); validação cruzada k-fold, onde se dividem os dados em *k* conjuntos, utilizando um conjunto para testes e *k-1* para treino (este processo é repetido *k* vezes, de modo a utilizar sempre conjuntos de treino diferentes) e o *leave-one-out*, método baseado na validação cruzada k-fold, em que *k* é igual ao número total de exemplos, criando *k* modelos, e testando o exemplo não incluído (este método torna-se dispendioso ao nível de tempo e processamento, quando utilizado para grandes conjuntos de dados).

Para a avaliação dos algoritmos utilizou-se o método de validação cruzada k-folds com *k=10*.

O modelo de classificação foi desenvolvido na *framework* Orange. Esta *framework* é desenvolvida com base em Python, e permite a construção de modelos visuais, disponibilizando um conjunto de funcionalidades para mineração de dados [14].

Criaram-se dois modelos, um para a classificação de imagens em formato png e outro para jpg, de modo a analisar a existência ou não de melhorias, e se foram significativas.

Após a construção do modelo, procedeu-se ao treino do mesmo e à análise aos resultados, nomeadamente quanto ao desempenho geral do classificador (AUC), exatidão (CA) precisão, cobertura (recall) e medida F1.

Para avaliar os modelos foram utilizadas diversas medidas de desempenho: exatidão, precisão, cobertura e F1.

A AUC (*área under curve*), mede o desempenho do classificador, tendo em conta a sua capacidade de distinção entre classes. Os seus valores tenderão para 1 quando o seu desempenho é ótimo e aproximam-se de 0 em resultados inversos.

Entende-se por exatidão (accuracy) a avaliação de quão próximo são os resultados da realidade. Desta forma, quanto maior for a exatidão, mais próxima é a classificação dos valores reais [14]. A exatidão é calculada através da fórmula $(VP + VN)/(VP + VN + FP + FN)$, em que: VP é o total de verdadeiros positivos; VN é o total de verdadeiros negativos; FP o total de falsos positivos; FN total de falsos negativos [15].

A precisão é a capacidade do classificador de não rotular como positiva uma amostra negativa [14]. O valor de recall, é intuitivamente a capacidade do classificador de encontrar todas as amostras positivas [14]. A função F1 representa a média harmónica entre a precisão e a cobertura, onde uma pontuação F1 atinge o seu melhor valor em 1 e a sua pior pontuação em 0, o mesmo acontece na precisão e cobertura. Em modelos que utilizam múltiplas classes e múltiplos rótulos, esta é a média da pontuação F1 de cada classe com ponderação, dependendo do parâmetro da média [14].

Para além destes valores, também se procedeu à construção da matriz de confusão, para uma melhor análise de resultados.

IV. APRESENTAÇÃO, ANÁLISE E DISCUSSÃO DE RESULTADOS

A criação de um modelo de classificação segue um conjunto de etapas, terminando com a análise dos resultados obtidos.

Neste estudo, foi construído um modelo de classificação para imagens em formato png e outro para imagens jpg. Sendo png um formato de compactação sem perdas e jpg um formato de compactação com perdas, tendo em conta a sua conversão, normalmente de 10:1, é interessante analisar os resultados obtidos utilizando imagens de cada um dos tipos.

Os valores utilizados para a afinação de parâmetros, foram os valores padrão. Tendo em conta a utilização de validação cruzada 10-folds, e os algoritmos LR, SVM e NB, a Tabela II apresenta os valores obtidos para cada uma das medidas em análise, utilizando imagens no formato png.

TABELA II. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO IMAGENS PNG

Modelo	AUC	CA	F1	Precision	Recall
SVM	0.996	0.943	0.943	0.944	0.943
NB	0.915	0.769	0.764	0.769	0.769
LR	0.999	0.981	0.981	0.981	0.981

Analisando a Tabela II, pode-se verificar que o algoritmo LR obtém os melhores resultados em todas as métricas em análise. O algoritmo SVM tem muito bons resultados, mas um pouco abaixo do anterior. Por sua vez o algoritmo NB, para este caso, fica mais distante dos valores atingidos pelos anteriores.

É importante analisar a classificação através da matriz de confusão para verificar onde é que cada algoritmo falha. A Figura 3 ilustra as matrizes de confusão de cada um dos algoritmos.

Logistic Regression					
	CADOICO	SBM	SBR	VMF	Σ
CADOICO	495	0	0	0	495
SBM	0	821	3	13	837
SBR	0	11	293	2	306
VMF	0	19	2	601	622
Σ	495	851	298	616	2260

Naïve Bayes					
	CADOICO	SBM	SBR	VMF	Σ
CADOICO	491	4	0	0	495
SBM	72	563	68	134	837
SBR	10	43	243	10	306
VMF	18	140	10	454	622
Σ	591	750	321	598	2260

SVM					
	CADOICO	SBM	SBR	VMF	Σ
CADOICO	495	0	0	0	495
SBM	0	811	3	23	837
SBR	0	15	290	1	306
VMF	0	47	2	573	622
Σ	495	873	295	597	2260

Figura 3. Matriz confusão de cada um dos modelos - imagens png

Analisando Figura 3, pode-se concluir que os algoritmos LR e SVM acertam na totalidade a classificação da classe CADOICO. No entanto, o algoritmo LR não classifica nenhuma das amostras das outras classes como CADOICO, enquanto o SVM classifica vinte imagens de forma errônea. Quanto ao NB, erra na classificação de quatro imagens da classe CADOICO e classifica de forma errada, nesta mesma classe, 111 imagens. O algoritmo classifica as quatro imagens CADOICO erradas como classe SBM, curiosamente a classe da qual classifica como CADOICO o maior número de forma errada, ou seja, confunde-se na classificação das imagens da classe CADOICO e SBM. Nesta primeira análise pode-se concluir que o algoritmo NB, neste problema específico, não é claramente uma boa solução para a classificação das imagens, sendo que em todas as classes analisadas teve resultados piores que os anteriores.

Na segunda análise, contemplando a classe SBM, verifica-se que tanto na utilização de LR como de SVM, esta classe é para ambos os modelos a mais confundida com a classe VMF, já que, em ambos os algoritmos, os valores errados têm uma distribuição de erro de cerca de 1/3 de imagens classificadas como SBR e 2/3 das imagens classificadas como VMF. O modelo SVM erra cerca de cinco vezes mais que o LR na classificação de imagens, das classes SBR e VMF, sendo que, para além destas, também classifica de forma errada dez imagens na classe CADOICO. Curiosamente, o modelo NB, não atinge os valores de 1/3 e 2/3 registados nos modelos anteriores, tendo taxas de erro mais próximas, neste caso o modelo errou em 296 imagens (mais de 13% do total de imagens).

Quanto à classe SBR, os modelos têm uma boa taxa de acerto: o LR apenas erra treze, dez como classe SBM e três como classe VMF. Por sua vez, o algoritmo SVM erra em dezanove imagens, classificando três como CADOICO e oito para SBM e VMF. Mais uma vez, os resultados do modelo NB ficam muito atrás dos restantes.

Por último, na classificação das imagens de VMF, o modelo LR, erra na classificação de catorze imagens, sendo que classifica todas de SBM; quanto ao SVM erra em vinte e quatro imagens, classificando sete como CADOICO e uma como SBR e as restantes dezasseis, ou seja 2/3 das imagens erradas como VMF. A par da classe SBM, nesta classe o NB também tem uma taxa de erro muito alta.

Teoricamente, a maior dificuldade do problema, prende-se na classificação assertiva das classes SBM, SBR e VMF, pela sua tonalidade. A distinção entre estas três classes e a classe CADOICO, previsivelmente é mais facilitada. Tendo em conta os resultados obtidos pelos três modelos, LR e SVM têm claramente superiores.

Utilizando o mesmo procedimento, procedeu-se à classificação das imagens jpg. A tabela III ilustra os valores obtidos em cada uma das métricas analisadas.

TABELA III. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO IMAGENS JPG

Modelo	AUC	CA	F1	Precision	Recall
SVM	0.994	0.960	0.960	0.960	0.960
NB	0.918	0.775	0.771	0.771	0.775
LR	0.998	0.978	0.978	0.978	0.978

Após uma análise comparativa entre a Tabela II e a Tabela III, podemos concluir que o modelo de classificação LR desce em todos os níveis ainda que nada de significativo; a nível de exatidão (AC) o NB é o único que melhora no formato jpg; quanto aos restantes valores tanto o SVM como o NB sobem a sua classificação nas restantes métricas.

É importante fazer-se uma análise da matriz confusão ilustrada na Figura 4, de modo a fazer uma comparação com os valores ilustrados na Figura 3.

Logistic Regression						Naïve Bayes					
	CADOICO	SBM	SBR	VMF	Σ		CADOICO	SBM	SBR	VMF	Σ
CADOICO	495	0	0	0	495	CADOICO	491	4	0	0	495
SBM	0	821	3	13	837	SBM	72	563	68	134	837
SBR	0	11	293	2	306	SBR	10	43	243	10	306
VMF	0	19	2	601	622	VMF	18	140	10	454	622
Σ	495	851	298	616	2260	Σ	591	750	321	598	2260

SVM					
	CADOICO	SBM	SBR	VMF	Σ
CADOICO	495	0	0	0	495
SBM	0	811	3	23	837
SBR	0	15	290	1	306
VMF	0	47	2	573	622
Σ	495	873	295	597	2260

Figura 4. Matriz confusão de cada um dos modelos - imagens jpg

Comparando os resultados, quanto à classe CADOICO, o algoritmo NB tem uma ligeira melhoria. Quanto à classe SBM, o modelo LR mantém os resultados, os modelos NB e SVM melhoram as suas classificações, sendo que no caso do SVM tem uma melhoria de classificação de sessenta imagens. Quanto à classe SBR, o modelo LR mantém, o NB classifica menos uma de forma assertiva e o SVM classifica mais três imagens de forma assertiva, diferenças muito reduzidas. A análise às imagens VMF é a única em que o LR classifica menos imagens de forma assertiva, num total de sete, NB e SVM também apresentam piores resultados.

A diferença ao nível de resultados não é conclusiva nem significativa, o único modelo de classificação que é melhor em todas as medidas na análise de imagens em formato png é o LR, sendo que o resultado não é muito relevante.

Dados os resultados, pode-se concluir que não é justificável a conversão das imagens ao formato png, pelo menos na nossa análise, sendo que a classe VMF é a única que apresenta para todos os algoritmos melhores resultados utilizando imagens de formato png.

O tempo de processamento é um fator bastante importante. Neste estudo foi medido o tempo de execução necessário para: processamento dos dados das imagens; treino do modelo NB, LR e SVM; total de processamento dos três algoritmos; tempo total geral.

As imagens deste conjunto no formato png ocupam em disco dezoito vezes mais e o tempo despendido para o seu processamento, por parte do modelo de classificação também é bastante maior. A Tabela IV apresenta os resultados do tempo de execução em minutos.

A Tabela IV, apresenta valores relativos ao tempo de processamento dos atributos das imagens (construção da matriz dos valores RGB), representada por TPI na tabela; tempo de treino de cada um dos modelos (TTNB, TTLR, TTSVM); o

tempo total de treino dos três algoritmos (TT PA); o total global de execução de todo o modelo. Os valores surgem representados para cada um dos tipos de formato de imagem, e no final surge a diferença verificada entre ambos.

TABELA IV. TABELA DE TEMPOS DE EXECUÇÃO, MEDIDA EM MINUTOS

	TPI	TT NB	TT LR	TT SVM	TT PA	Total Geral
jpg	1:51:04	0:24:51	0:52:27	4:01:02	5:18:20	7:09:24
png	6:43:57	0:22:06	1:02:27	5:02:12	6:26:45	13:10:42
Dif.	+4:52:53	-0:02:45	+0:10:00	+1:01:10	+1:08:25	+6:01:18

Os resultados do tempo de execução, expressos na Tabela IV, permitem concluir que, o tempo de processamento de imagens no formato png é 3,6 vezes maior, quando comparado com o tempo de processamento de imagens jpg. A diferença do tempo de execução dos algoritmos não é exorbitante, mas quando somada ao valor de processamento (tempo de execução do modelo), a diferença é cerca de seis minutos.

Analisando os mesmos dados, verifica-se que, o algoritmo SVM é o mais dispendioso, demorando cerca de 76% do tempo de processamento total dos algoritmos no formato jpg e cerca de 78% no formato png. No formato jpg, o algoritmo SVM utiliza 56% do tempo total (Total Geral), no formato png desce para 38%.

Estes dados foram analisados numa amostra de 2260 imagens, estamos a falar numa questão de minutos, mas que se transformará em horas, em amostras de dados com milhares de imagens.

V. CONCLUSÕES E TRABALHO FUTURO

Este trabalho teve como finalidade o desenvolvimento de um modelo de classificação de rochas. Foi desenvolvido passo a passo: começando na recolha de imagens, passando à preparação das imagens e sua classificação, criando assim, o conjunto de dados. Construiu-se, depois, o modelo de classificação e, por fim, passou-se ao teste e análise de resultados.

Para a análise foram utilizados três algoritmos de classificação: SVM; Naive Bayes e Logistic Regression. Nesta primeira fase, construiu-se um modelo com base em algoritmos padrão, sem grandes afinações.

Após o treino do modelo procedeu-se à análise dos resultados. De forma geral, o modelo Logistic Regression obteve os melhores resultados na classificação de todos os tipos de pedra, considerando-se desta forma, o melhor algoritmo de classificação testado neste trabalho. O facto de ser um algoritmo que nos deu bons resultados não o assume como melhor face aos restantes, apenas podemos concluir que na análise destes dados foi o que obteve melhores resultados a todos os níveis.

Uma outra conclusão que podemos retirar, é que o formato jpg, sendo um formato de compressão com perdas, torna-se mais leve e menos moroso a processar. Tendo em conta que em alguns casos até apresenta melhores resultados, é possível concluir que o formato jpg, é o melhor formato para este problema, já que apresenta um menor custo de armazenamento e processamento.

Curiosamente o LR tem a mesma quantidade de imagens classificadas de forma assertiva em todas as classes à exceção da classe VMF, que por acaso é onde os restantes modelos também não conseguem melhorar a sua classificação.

Este estudo utilizou apenas quatro tipos de pedra, sendo estas as mais comercializadas pela empresa. O próximo objetivo será criar um modelo capaz de classificar a totalidade de quinze tipos: doze de pedras lisas e três de pedras com padrões. Este desenvolvimento, irá permitir, proceder à análise de defeitos nas chapas e classificar esses mesmos defeitos, tendo em conta um conjunto de políticas de seleção que podem ser distintas para cada tipo de pedra.

REFERÊNCIAS BIBLIOGRÁFICA

- [1] Carvalho, J. M., Lisboa, J. V., Casal Moura, A., Carvalho, C., Sousa, L. M., Leite, M. M. (2013). Evaluation of the Portuguese ornamental stone resources. In Key Engineering Materials (Vol. 548, pp. 3-9). Trans Tech Publications.
- [2] Portugal exportou mais 10,5% de pedra natural em 2018 num total de 378 ME. (16 de Março de 2019). Diário de Notícias. Obtido de <https://www.dn.pt/lusa/interior/portugal-exportou-mais-105-de-pedra-naturalem-2018-num-total-de-378-me-10687767.html>
- [3] Costa, J. C., Espírito-Santo, M. D., Arsénio, P. (2010). Guia geobotânico da excursão ao Parque Natural da Serra de Aires e Candeeiros. Quercetia, 10, 5-107.
- [4] Pooja, Sharma, A., Sharma, A.: Machine Learning: A Review of Techniques of Machine Learning. Publisher, Journal of Applied Science and Computations. p.538-541 Volume 5, Issue 7, July /2018
- [5] Dinov, I. D.: Probabilistic Learning: Classification Using Naive Bayes. In Data Science and Predictive Analytics (pp. 289-305). Springer, Cham. (2018).
- [6] Starkweather, J., Moske, A. K. (2011). Multinomial logistic regression. Consulted page at September 10th: http://www.unt.edu/rss/class/Jon/Benchmarks/MLR_JDS_Aug2011.pdf, 29, 2825-2830.
- [7] David A. Freedman (2009). Statistical Models: Theory and Practice. [S.l.]: Cambridge University Press. p. 128.
- [8] Nicolau, J. (2014). Determinantes do voto no primeiro turno das eleições presidenciais brasileiras de 2010: uma análise exploratória. Opinião Pública, 20(3), 311-325.
- [9] Fiore, M., Vrontis, D., Silvestri, R., Contò, F. (2016). Social media and societal marketing: a path for a better wine? Journal of Promotion Management, 22(2), 268-279.
- [10] Rajesh, K., Ramaswamy, V., Kannan, K., Arunkumar, N. (2019). Satellite cloud image classification for cyclone prediction using dichotomous logistic regression based fuzzy hypergraph model. Future Generation Computer Systems, 98, 688-696
- [11] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2818-2826).
- [12] Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Advances in neural information processing systems (pp. 1097-1105).
- [13] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- [14] <https://docs.orange.biolab.si/3/data-mining-library/reference/evaluation.cd.html> (acedido em 06-04-2020)
- [15] Borges, L. S. (2016). Medidas de Acurácia diagnóstica na pesquisa cardiovascular. Int J Cardiovasc Sci, 29(3), 218-22.