

UTILIZANDO APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO DE MINÉRIOS A PARTIR DE IMAGENS DE ROCHAS CAPTURADAS DE CHAPAS MICROSCÓPICAS

HENRIQUE P. BORGES¹; MATHEUS S. DA SILVA¹; MARILTON S. DE AGUIAR¹

¹*Universidade Federal de Pelotas – {hpborges,msd.silva,marilton}@inf.ufpel.edu.br*

1. INTRODUÇÃO

Geologia é uma ciência natural multidisciplinar que estuda o planeta terra, incluindo os materiais, a estrutura e os processos que nele atuam. Por exemplo, uma aplicação desse conhecimento pode ser feita para evitar a construção em áreas de risco, exploração de recursos naturais e predizer mudanças climáticas. Um dos pilares dessa ciência é a mineralogia, estudo da física e da química de materiais naturais, sólidos ou cristalinos.

O objeto de estudo dessa área, o minério, é um sólido homogêneo que ocorre naturalmente com definida composição química e organização atômica, geralmente formados por processos inorgânicos. A identificação correta de minérios é essencial e recorrente na mineralogia, o método mais rápido e prático é com o uso de chapas microscópicas de rochas e realizar a classificação via um microscópico com luz polarizada. Esta é uma tarefa que geralmente exige anos de experiência do profissional para identificar as propriedades óticas da chapa do minério (ROSS et al. 2001; ALIGHOLI et al. 2015).

Atualmente, o uso de aprendizado de máquina é feito em várias áreas, incluindo, astronomia, indústria, medicina, entre outros. É uma poderosa e versátil ferramenta para automatizar tarefas que se realizadas por uma pessoa, pode demandar mais tempo e fica sujeito ao erro humano. Existem muitos casos de sucesso, incluindo, reconhecimento de letras cursivas de receitas médicas, reconhecimento automático de amadurecimento de fruta, monitoramento contínuo de atividade sísmica de vulcões, predição de clima, análise de tráfico e entre outros (MLYNARCZUK et al. 2013).

Existem duas formas de realizar o aprendizado de máquina: o método supervisionado e o não supervisionado. O método não supervisionado, que também pode ser chamado de clusterização, agrupa elementos similares e para cada novo elemento diz em que grupo, ou *cluster*, ele se encaixa.

O método supervisionado, o qual será detalhado posteriormente, pode ser considerado aprendizado através de exemplos, ou seja, selecionam-se alguns elementos para treino, onde, cada um possui um rótulo de classificação. Neste método, a máquina vai tentar inferir suas próprias regras para classificar em rótulos previamente definidos, a cada novo elemento vão ser aplicadas essas regras e inferir qual rótulo teria este novo elemento.

A definição do aprendizado é bastante genérica assim como sua implementação facilitando sua aplicação para diferentes propósitos, como visto anteriormente, em várias áreas do conhecimento. Mesmo assim sua aplicação em geologia ainda é limitada (MLYNARCZUK et al. 2013).

Neste contexto, este trabalho propõe o uso de aprendizado de máquina nas fotos de chapas de microscópicas de rochas visando automatizar esta classificação.

2. METODOLOGIA

O método de implementação do aprendizado de máquina supervisionado pode ser abstraído em etapas. A primeira é a captura de dados brutos, a segunda é o tratamento desses dados transformando em dados elaborados, a terceira é o treinamento de um algoritmo de aprendizado usando os dados elaborados e a última é mensurar sua eficácia predizendo entradas novas. Foram usados como base os estudos de BAYKAN; YILMAZ (2010), THOMPSON et al. (2001) e IZADI et al. (2013). Cada etapa será melhor detalhada a seguir.

Há dois grandes pontos inerentes a captura de imagens de minérios. O primeiro ponto é que os microscópicos possuem duas fontes de luz polarizada, uma acima e outra abaixo da chapa. Assim a chapa pode ser visualizada de dois modos, uma somente com a luz acima ligada, chamada de luz polarizada simples, outra com as duas fontes ligadas, chamada de luz polarizada cruzada.

O minério muitas vezes não demonstra cor na luz polarizada simples, então é necessário visualizar com luz polarizada cruzada, mas isso ainda não é suficiente pois de acordo com o ângulo de incidência da luz o minério pode estar em extinção, isto é, ficar visualmente preto, como pode ser observado especialmente na área destacada na Figura 1.

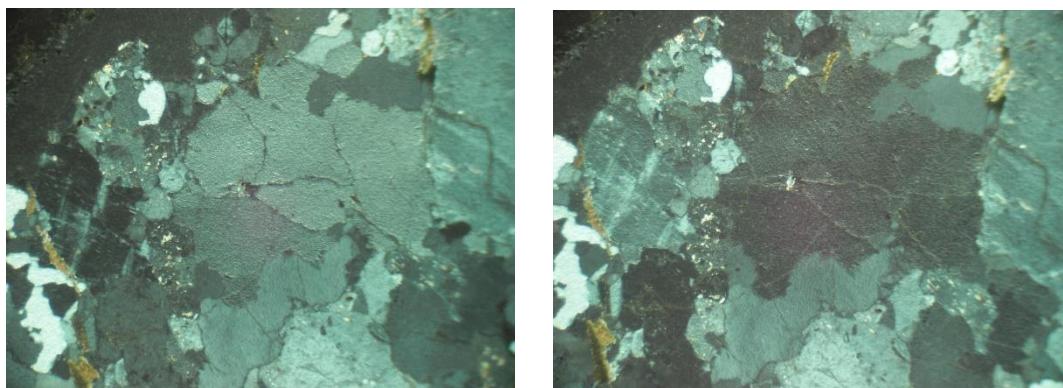


Figura 1: Exemplo de minério em extinção

Existem duas formas de lidar com isso uma delas é girando a chapa sob a luz e a outra é girar a própria luz sob a chapa. O última forma é mais desejada pois assim garante que a posição espacial do minério na foto é mantida para toda variação de luz. Outro problema é como fazer a segmentação da imagem adquirida. A foto da chapa é composta por um conjunto de minérios e se deseja saber a identificação de apenas um desses por vez.

Os dados brutos serão capturados pelo departamento de Geologia da UFPel, onde serão tiradas fotos com uma câmera digital através da lente de um microscópico de luz polarizada simples e cruzada. É colocada uma chapa microscópica de rocha no microscópico e são tiradas fotos de vários ângulos de modo que a chapa manifeste cor mais brilhante e também capturar com ângulo de extinção. No momento de captura o minério será identificado por um geólogo.

Na próxima etapa será identificada a área em que o minério de interesse está localizado dentro da foto. E com base de todos os estudos citados, as informações de cor daquela região vai ser retirada e tratada, isto é, vai ser transformado do espaço de cores RGB para CIE.

Segundo o levantamento bibliográfico realizado, o espaço de cores RGB é muito sensível à luz, isto é, uma variação na luz branca varia muito a quantidade

das cores primárias (componentes RGB). Então, recomenda-se usar um espaço de cores onde isole a luz branca ou quantidade de brilho das cores, nos estudos citados utilizou-se o espaço de cor HSV (*Hue, Saturation e Value*). Neste trabalho, a proposta de implementação é utilizar a transformação para o espaço de cor LAB (*Lightning, a x b*) que é indicado como melhor escolha para um aprendizado de máquina segundo o estudo de ALIGHOLLI et al. (2015).

O algoritmo vai ser treinado com um conjunto de informações de cor junto com seu rótulo de identificação feito na etapa de captura. As informações de cor LAB são representadas por três valores fracionários, o primeiro valor é o intervalo [0 ; 100] e representa a quantidade de brilho, o segundo e o terceiro valor são do intervalo [-128 ; 128] e representam uma coordenada de cor. Todos esses valores vão ser normalizados em [-1 ; 1]. As informações do minério serão captadas em dois momentos a de maior brilho (maior valor *L*) e de menor brilho, isto é para capturar a informação de pleocroísmo (a propriedade de mudança de cor do minério). Assim cada elemento vai conter duas informações LAB.

Logo após, cada elemento pode ser posicionado em um espaço de seis dimensões (duas para cada valor LAB). Os algoritmos de aprendizado de máquina que vão ser usados neste trabalho, não contemplados no estado da arte, serão *nearest neighbour* e *k-nearest neighbour*. Cada entrada nova será transformada, normalizada e colocada nesse espaço de seis dimensões e vai identificar qual é o outro elemento, ou os *k* elementos mais próximos, e ver sua classificação e de acordo com esta classificar o novo elemento.

Vai ser construída uma tabela comparando os resultados e eficácia do algoritmo. Como todos os elementos já foram previamente classificados usa-se uma parcela desses como treinamento, e outra parcela para apurar a eficácia. Insere-se um elemento para testar como o algoritmo o classifica e compara com a classificação de um geólogo, assim, mensura-se a eficácia do algoritmo para classificar novos elementos. Este passo será repetido várias vezes para gerar uma aleatoriedade entre os elementos usados para treinamento ou teste.

3. RESULTADOS E DISCUSSÃO

Até o presente momento, foi realizada a revisão bibliográfica, com uma filtragem de artigos publicados com proposta similares a fim de perceber o estado da arte que este trabalho será inserido. Nessa pesquisa se notou uma carência no uso de ferramentas computacionais para classificação de minérios em chapas microscópicas de rochas. As próximas etapas são digitalizar e elaborar os dados brutos para depois implementar e testar diferentes algoritmos de aprendizado de máquina e verificar se algum tratamento a mais nos dados (como redução de ruído da imagem, utilizar outro espaço de cores, ou uso de metadados) influencia significativamente na eficácia do algoritmo.

4. CONCLUSÕES

Todos os artigos encontrados como referencial teórico, exceto um, que utilizam fotos de chapas de rochas microscópicas para classificação de minério, usaram redes neurais para fazer a classificação.

Apesar dos artigos apresentarem bons resultados (acima de 80% de eficácia) ainda deixam margem para exploração de técnicas alternativas, uma vez

que este tipo de abordagem é pouco escalável e exigem tempo significativo de implementação e de treinamento.

Este trabalho se propõe em comparar estes resultados com algoritmos de aprendizagem mais simples e rápidos. Assim, a base científica amplia-se com a comparação de diferentes algoritmos consagrados na literatura computacional dando maior apoio nessa importante tarefa da geologia.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ALIGHOLI, S; KHAJAVI, R. R, M. Automated mineral identification algorithm using optical properties of crystals. **Computers & Geosciences**, Mashhad, Iran, v. 85, n.1, p. 175-183, 2015.

BAYKAN, N; YILMAZ, N. Mineral identification using color spaces and artificial neural networks. **Computers & Geosciences**, Konya, Turkey, v. 36, n.1, p. 91-97, 2010.

IZADI, H; SADRI, J; MEHRAN, N. Intelligent mineral identification using clustering and artificial neural networks techniques. **Pattern Recognition and Image Analysis (PRIA), 2013, First Iranian Conference on**. Birjand, Iran, p. 1-5, 2013.

MLYNARCZUK, M; GÓRSZCZYK, G; SLIPEK, B. The application of pattern recognition in the automatic classification of microscopic rock images. **Computers & Geosciences**, Krakow, Poland, v.60, n.1, p.126-133, 2013.

ROSS, B; FUETEN, F; YASHKIR, D. Automatic mineral identification using genetic programming. **Machine Vision and Applications**, Ontario, Canada, v. 13, n.2, p. 61-69, 2001.