

Análise de Imagens Hiperespectrais para reconhecimento de depósitos de minério de ferro utilizando aprendizado não supervisionado^{*}

Érica S. Pinto^{*} Gustavo Pessin^{**} Alan K. Rêgo Segundo^{***}

^{*} Departamento de Ciências da Computação, Universidade Federal de Ouro Preto, MG, (e-mail: erica.lins15@gmail.com).

^{**} Instituto Tecnológico Vale, Ouro Preto, MG (e-mail: gustavo.pessin@itv.org)

^{***} Departamento de Controle e Automação, Universidade Federal de Ouro Preto, MG, (e-mail: alankardek@ufop.edu.br)

Abstract: Hyperspectral Imaging Systems (HSI) collect spectral data and spatial images simultaneously and continuously in hundreds of narrow spectral bands to generate a data cube. Specifically in mineralogy, remote sensing techniques using hyperspectral images are becoming increasingly popular on remote mapping of mineral formations. Datasets containing hyperspectral images from sensors such as Hyperion installed on the NASA's Earth Observing satellite 1 (EO-1) can be found online. Considering these facts, we propose in this work the use of analysis and pattern recognition techniques in data cubes from HSI systems, more specifically from EO-1 Hyperion satellite. The hyperspectral image analysed includes the Carajás mine (Pará, BR) for the purpose of reconnaissance and identification of iron ore deposits using unsupervised learning and K-Means clustering method. The results show that about 6.72% of the analysed area is composed of iron ore, which corresponds to approximately $51km^2$.

Resumo: Sistemas de imagens hiperespectrais (HSI) coletam dados espectrais e imagens espaciais de forma simultânea em centenas de bandas espectrais estreitas de forma contínua para gerar um cubo de dado. Especificamente na mineralogia, as técnicas de sensoriamento remoto utilizando imagens hiperespectrais estão se tornando cada vez mais populares para mapeamento remoto das formações mineralógicas. Datasets provenientes de satélites como o Earth Observing 1 (EO-1) Hyperion da NASA contendo imagens hiperespectrais podem ser encontrados online. Considerando estes fatos, é proposto neste trabalho o emprego de técnicas de análise e reconhecimento de padrões em cubos de dados provenientes de sistemas HSI, mais especificamente do satélite EO-1 Hyperion. A imagem hiperespectral analisada inclui a mina de Carajás no estado do Pará, Brasil, com a finalidade de reconhecimento e identificação de depósitos de minério de ferro utilizando aprendizagem não supervisionando e o método de clusterização K-Means. Os resultados demonstram que cerca de 6,72% da área analisada seja composta por minério de ferro, o que corresponde a $51km^2$, aproximadamente.

Keywords: Hyperspectral Images; Remote Sensing; Iron ore; Hyperion; Unsupervised learning; K-Means.

Palavras-chaves: Imagens Hiperespectrais; Sensoriamento Remoto; Minério de Ferro; Hyperion; Aprendizagem não-supervisionada; K-Means.

1. INTRODUÇÃO

A espectroscopia é a investigação da interação entre a radiação eletromagnética (EMR) e a matéria. O objeto de estudo da espectroscopia são fenômenos físico-químicos de interação como a reflexão, refração e difração ou alteração nos níveis de energia de moléculas quando a EMR entra em contato com um determinado objeto. Assim,

^{*} Os autores agradecem o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); Vale SA; e Departamento de Ciências e Computação da Universidade Federal de Ouro Preto.

cada elemento químico existente possui uma assinatura espectral única em resposta à exposição a uma faixa de EMR existente no espectro.

O sensoriamento remoto é definido como qualquer técnica usada para obter informações sobre um objeto de estudo que não requer um contato direto (Campbell and Wynne (2011)). Assim, trata-se de um conjunto de técnicas baseadas na espectroscopia que possibilita a obtenção de informações sobre um objeto de estudo por meio do registro da interação da EMR com o mesmo. A obtenção desses dados de interesse é realizada por sensores distantes, ou remotos. O sensoriamento remoto é uma metodologia que pode ser adotada tanto em dispositivos no solo como em

aviões, navios ou satélites. Dois passos básicos definem essa técnica, o primeiro consiste em ter dispositivos que captam como a radiação eletromagnética (e.g.: luz ou calor) incide em um determinado objeto. O segundo passo ocorre quando esses dados coletados são analisados para extrair algum tipo de informação de interesse acerca do objeto.

As interações entre a matéria e as EMR podem ser avaliadas sob diferentes perspectivas. A forma com que a amostragem espectral é realizada define diferentes modalidades de investigação e apresentação de dados espectrais. A abordagem pancromática, por exemplo, utiliza uma única amostra para uma grande largura de banda e uma extensa faixa de comprimento de onda (λ). Já para uma análise multiespectral existe um conjunto de amostras discretas ao longo do espectro eletromagnético com λ bem definidos. Para a terceira e última metodologia a coleta de dados é realizada de forma contínua entre uma região específica do espectro eletromagnético em uma resolução espectral alta, a ela se dá o nome de análise hiperespectral. Em concordância com Mukherjee et al. (2009), uma das vantagens que a abordagem hiperespectral possui se comparada à metodologia multiespectral, é a resolução espectral mais alta, oferecendo, assim, o potencial de aumentar a discriminação de materiais e precisão de detecção de alvo.

Sensores hiperespectrais gravam a energia eletromagnética refletida pela superfície da Terra ao longo do espectro eletromagnético que vai do comprimento de onda da região visível até a região perto do infravermelho em centenas de faixas contíguas estreitas. Essas larguras de banda resultam em uma resposta espectral contínua e detalhada de cada pixel da imagem, fornecendo informações precisas e com acurácia sobre seus constituintes (Sahoo et al. (2012)).

Sistemas de imagens hiperespectrais (HSI) coletam dados espectrais e imagens espaciais de forma simultânea em centenas de bandas espectrais estreitas continuamente formando um cubo de dados (Alkhatib and Velez-Reyes (2019)). O sensoriamento remoto hiperespectral é utilizado em uma ampla gama de aplicações como na ecologia, agricultura, mineralogia e vigilância.

Especificamente na mineralogia, as técnicas de sensoriamento remoto estão se tornando cada vez mais populares para o mapeamento remoto das formações minerais da Terra, de acordo com Patteti et al. (2015). As acuidades espaciais e espectrais em constante evolução de sensores de satélite e aerotransportadores, ampliam ainda mais a habilidade das metodologias de sensoriamento remoto para exploração mineral e compreensão da origem dos depósitos minerais.

Além de permitir o mapeamento de estruturas minerais, as tecnologias de sensoriamento remoto hiperespectral permitem a identificação de diferentes tipos minerais, incluindo múltiplos tipos de minérios de ferro como hematita, magnetita e goethita (Shaik et al. (2021)). Cada mineral desempenha uma absorção e padrão de reflectância espectral únicos no espectro eletromagnético, permitindo assim, a identificação de cada elemento e abundância relativa na amostra de rocha analisada em um local pré-determinado.

Datasets provenientes de satélites como o Earth Observing 1 (EO-1) Hyperion da NASA contendo imagens hiperes-

pectrais podem ser encontrados online por meio da plataforma *Earth Explores* da United States Geological Survey (2021) ou USGS. Em trabalhos como os desenvolvidos por Shaik et al. (2021), Khurshid et al. (2006) e Gupta and Venkatesan (2020), estes dados são utilizados em prol de analisar, processar e interpretar dados de imagem hiperespectrais. Especificamente no caso dos trabalhos desenvolvidos por Shaik et al. (2021) e Gupta and Venkatesan (2020), o objetivo é identificar depósitos minerais de minério de ferro em áreas específicas do planeta.

De acordo com Gupta and Venkatesan (2020), existem duas abordagens que podem ser empregadas para a análise de dados provenientes de HSIs. A primeira delas é baseada em técnicas de aprendizagem supervisionada e visa confrontar as assinaturas espectrais provenientes de cada um dos pixels da HSI com dados espectrais coletados de amostras locais analisadas em laboratório. Assim, a classificação mineral das áreas da HSI é realizada utilizando os dados de sistemas hiperespectrais coletados por satélites e a análise laboratorial como alvo a ser encontrado na imagem. A segunda é baseada em aprendizagem não supervisionada em que uma HSI é dividida em vários grupos de características espectrais semelhantes e são clusterizados em classes, sem qualquer conhecimento de dados coletados localmente.

Neste trabalho foram aplicadas técnicas de análise e reconhecimento de padrões em cubos de dados provenientes de sistemas HSI. Uma imagem hiperespectral proveniente do satélite EO-1 Hyperion foi analisada para reconhecimento e identificação de depósitos de minério de ferro no Brasil, mais especificamente em uma imagem hiperespectral que inclui a mina de Carajás no Pará, Brasil. A escolha desta região em específico é estratégica por dois motivos. O primeiro deles devido ao conhecimento óbvio da existência de uma área de exploração de minério de ferro e que, por consequência, vai refletir o perfil espectral do minério de ferro na região da mina. O segundo motivo é devido ao fato de que a aprendizagem realizada neste trabalho precisa ser não supervisionada em função da inviabilidade de coleta de amostras locais e análise espectral laboratorial.

Para tal finalidade, o software ENVI foi utilizado juntamente com o método de aprendizagem não supervisionada K-Means. O *Environment for Visualizing Images* ou ENVI é um software de visualização, análise e interpretação de dados na área de Sensoriamento Remoto. O software inclui pacotes avançados e ferramentas de pré e pós processamento de imagens para análise espectral (Sahoo et al. (2012)). Além disso, possui uma plataforma de suporte ao desenvolvimento de uma aprendizagem não supervisionada que inclui o método K-Means.

2. TRABALHOS RELACIONADOS

Shaik et al. (2021) apresentam um estudo de caso feito em Bailadila, Índia em que é realizado a caracterização e mapeamento de classes de minerais de ferro, em específico a hematita (Fe_2O_3), utilizando-se de técnicas de sensoriamento remoto hiperespectral, dados espectrais provenientes do satélite Hyperion (EO-1), coleta de amostras de diferentes tipos de hematitas em campo e, métodos de aprendizagem supervisionada. De acordo com Shaik et al. (2021), a absorção espectral na região próxima ao infravermelho e luz visível fornece informações essenciais

sobre os óxidos de ferro, já que o íon de ferro (II) e (III) em rochas são responsáveis pelo fenômeno de absorção da radiação eletromagnética nas regiões do espectro com comprimentos de onda de 900 a 1100 nm e 750 a 870 nm, respectivamente.

Shaik et al. (2021) comparam os dados hiperespectrais provenientes do satélite com a assinatura espectral de cada uma das amostras de hematita coletadas em campo utilizando *Spectral angle mapper* ou SAM. O SAM é um método automatizado para comparar diretamente os espectros da imagem com um espectro conhecido, de acordo com Shaik et al. (2021). Assim, ele calcula a similaridade espectral entre o espectro da imagem e o espectro de referência obtido do laboratório ou do espectro de reflectância coletado do campo em condições atmosféricas naturais. Logo, a diferença angular é medida entre os espectros de imagem e os espectros de referência para cada pixel em radianos representados na Equação 1.

$$\text{Cos}\varphi = \frac{\sum_{n=1}^i t_i r_i}{\sqrt{\sum_{n=1}^i t_i^2} \sqrt{\sum_{n=1}^i r_i^2}} \quad (1)$$

em que φ é o ângulo espectral, t se referem ao espectro de teste, r se referem ao espectro de referência e n denota o maior número de banda. A acurácia geral encontrada no estudo proposto por Shaik et al. (2021) foi de 88,2%, sendo que o estudo foi realizado com a coleta de amostras de diferentes tipos de hematita em localizações variadas de Bailadila. A metodologia proposta por Shaik et al. (2021) apresentou uma acurácia relativamente alta. Porém, a principal desvantagem do método apresentado é a necessidade de coleta de dados em campo para o emprego do SAM.

Patteti et al. (2015) propõe um modelo baseado em Redes Neurais Artificiais ou RNA para classificação de minérios em imagens hiperspectrais desenvolvido com base no uso apenas das bandas de absorção essenciais dos espectros do minério de ferro. Assim, é possível reduzir a dimensionalidade das entradas da rede neural artificial e inibir as influências de bandas ruidosas para a classificação. O método escolhido por Patteti et al. (2015) também utiliza de técnicas de aprendizagem supervisionada e o modelo de RNA foi treinado com dados laboratoriais de amostras de minério de ferro coletadas em depósito existente e confrontados com dados de imagens hiperespectrais do satélite Hyperion. Como resultado, Patteti et al. (2015) obtiveram uma precisão no conjunto de treino de 97% e para conjunto de teste 71%. Os resultados de acurácia obtidos por Patteti et al. (2015) indicam um possível sobreajuste ou *overfitting*, visto que o modelo de RNA gerado se ajusta muito bem ao conjunto de dados de treino, mas se mostra menos eficaz para prever novos resultados.

Gupta and Venkatesan (2020) apresentam um estudo de caso que utiliza técnicas de aprendizagem não supervisionada para identificação mineral em imagens hiperespectrais coletadas no estado de Tamil Nadu na Índia. Para diminuir a dimensionalidade e tamanho dos dados, Gupta and Venkatesan (2020) utilizam a técnica de análise de componentes principais ou PCA com uma abordagem de seleção de bandas. Devido à indisponibilidade e inviabi-

lidade da existência de amostras coletadas no local de estudo, os autores optaram por realizar uma aprendizagem não supervisionada clusterizando os dados com o método K-means.

De acordo com Gupta and Venkatesan (2020), essa metodologia é aplicada nos dados reduzidos e, posteriormente, ele utiliza uma metodologia supervisionada, as máquinas de suporte vetorial ou SVM. O SVM é utilizado para classificar os dados da HSI como um todo, ou seja, o conjunto de dados completo e antes da aplicação do PCA, possuindo como *target* o resultado da clusterização feita utilizando o k-means. Assim, Gupta and Venkatesan (2020) conseguiram estabelecer a acurácia de 76,03% da metodologia adotada como um todo.

A metodologia não supervisionada adotada por Gupta and Venkatesan (2020) foi a escolhida como norte para a realização deste trabalho devido relativa simplicidade dos métodos empregados e a inviabilidade de coleta de amostras de minério na região de estudos, bem como a falta de equipamentos laboratoriais para a realização da análise espectral das amostras caso elas estivessem disponíveis.

3. SATÉLITE EO-1 E O SENSOR HYPERION

O EO-1 é um gerador de HSI de alta resolução que produz mais de 242 canais espectrais exclusivos de 0,355 a 2,577 μm com uma resolução espectral de 10nm de acordo com Sahoo et al. (2012). O instrumento, Hyperion, opera em forma de vassoura, por varrer e percorrer, simultaneamente, uma largura de cena padrão de 7,7km e um comprimento de 100km por imagem coletada. Cada pixel da HSI possui 30m de resolução espacial, equivalendo a 855,5 mil pixels por HSI, aproximadamente. Este satélite lançado nos anos 2000 possui dois espectrômetros que operam em diferentes faixas do espectro. O primeiro opera entre 0,355 e 1 μm totalizando 70 bandas, em uma parte do espectro chamada de VNIR (luz visível e perto do infravermelho), já o segundo opera entre 0,9 e 2,5 μm totalizando 172 bandas e em uma parte do espectro chamada de SWIR (ondas curtas do infravermelho).

Em suma, cada imagem gerada pelo Hyperion possuem uma área de cobertura de 770 km^2 resultando em aproximadamente 855 mil pixels. Cada um desses pixel possui o perfil espectral ao longo de 242 bandas e refletem os diferentes materiais constituintes da superfície analisada.

O Hyperion possui uma alta resolução radiométrica de 16 bits. Logo, sua capacidade de distinguir entre valores de escala de cinza na aquisição de uma imagem é alta, visto que, quanto maior a resolução mais valores de escala de cinza podem ser armazenados e, portanto, mais diferenças no reflexo nas superfícies da terra podem ser detectadas.

4. METODOLOGIA

4.1 Método K-means

O K-means é um método de agrupamento em torno de centros ou centroides dos dados provenientes de uma base para a realização de uma aprendizagem não supervisionada.

O algoritmo básicos do método k-means inclui: fixar k centroides de maneira aleatória, um para cada cluster; associar cada instância ao seu centroide mais próximo/similar; e recalculer os centroides com base nos indivíduos classificados até que ele não se movimente mais no espaço e o algoritmo termine.

A principal vantagem deste método decorre de sua simplicidade. Porém, a escolha do ponto inicial do centroides e do número de clusters se torna um empecilho quando não estabelecidos corretamente. As próximas duas subseções são destinadas a oferecer alternativas para contornar as desvantagens do método e realizar o processo de clusterização por meio do K-means de forma mais acurada.

Escolha do ponto inicial dos centroides : O ponto inicial dos centroides pode ser definido de várias formas, dentre elas é possível inicializa-lo em posições aleatórias diferentes, computar o custo, repetir esse processo um número arbitrário de vezes e escolher a posição inicial de menor custo em meios às testadas. Outra alternativa é utilizar os pontos mais distantes do conjunto de dados, porém, essa abordagem é sensível à outliers.

Definição do número de clusters : O número de clusters pode ser definido de várias formas. A primeira delas exige o conhecimento do domínio de forma que seja possível identificar e determinar em quantos clusters os dados serão agrupados.

Uma segunda técnica empírica de obtenção de número de clusters é o método do cotovelo. A variância dentro do cluster é uma medida de compactação do mesmo e quanto menor o valor da variância dentro do cluster, maior a compactação do agrupamento formado. Então, o método do cotovelo propõe realizar o processo de clusterização com um número variado e crescente para k, de forma que a cada iteração a variância dos clusters vá diminuindo e o k ótimo é determinado quando, quantitativamente, essa variância se estabiliza.

Para a realização deste trabalho a metodologia adotada no uso do K-Means foi de variar o número de clusters entre 4 e 7 e analisar visualmente o que melhor representa a distribuição da imagem, isto porque, visualmente, a imagem hiperespectral da área escolhida para estudo aparenta ter de 4 a 7 superfícies distintas.

4.2 Dataset

O dataset utilizado para a realização deste trabalho foi obtido no site *United States Geological Survey* (USGS) por meio da ferramenta EarthExplorer (EE). A interface de usuário EE é uma ferramenta online de busca que oferece suporte à pesquisa de inventários de satélite, aeronaves e outros sensores remotos por meio de recursos de consulta interativos e baseados em texto, United States Geological Survey (2021). Em específico relacionado a imagens hiperespectrais existe datasets provenientes do satélite EO-1 Hyperion. Devido à sua interface interativa, a ferramenta oferece uma busca de base de dados feita através do mapa-múndi. Assim, a área da mina de Carajás foi selecionada tendo como centro as coordenadas $06^{\circ} 04' 11'' S$, $050^{\circ} 09' 42'' W$ e 6 km de raio como mostra a Figura 1.

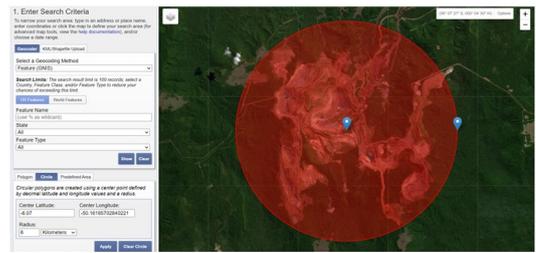


Figura 1. Interface de busca da ferramenta EE do site USGS e local de estudo escolhido (Mina de Carajás). Fonte: United States Geological Survey (2021).

Com a área de estudo estabelecida é possível observar os conjuntos de dados disponíveis para aquela região na aba resultados. O escolhido foi o coletado mais recentemente, em 2016 de nome EO1H2240642016333110KF_AK4_01. O dataset é referente à imagem hiperespectral (área representada em retângulo 2) e contempla boa parte da área de estudo marcada em vermelho na Figura 2.

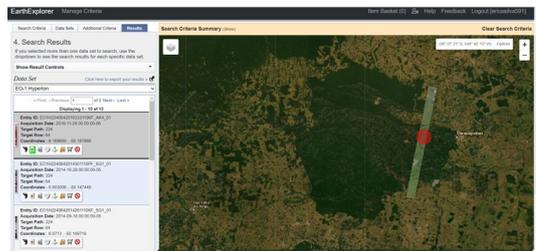


Figura 2. Interface de busca da ferramenta EE do site USGS e indicação do dataset escolhido que engloba a área de estudo. Fonte: United States Geological Survey (2021).

Cada pixel da imagem representada na Figura 3 possui uma resolução espacial de 30 m. Além de sua localização espacial, a cada pixel está associado dados espectrais referentes às características de material de sua região.

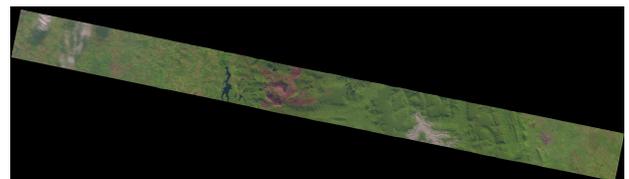


Figura 3. Imagem hiperespectral rotacionada em 90° e em alta resolução. Fonte: United States Geological Survey (2021).

O formato dos dados disponíveis representam o nível de processamento pelo qual esses dados passaram. O escolhido para a realização deste trabalho foi o Level 1R ou L1R que possui dados radiometricamente corrigido, ou seja, com interferências atmosféricas visando a superfície reduzidas e não geometricamente re-amostrado. Ele está disponível em formato HDF, é escrito em linhas de bandas intercaladas e possui 198 bandas calibradas das 242 disponíveis.

O cubo de dados espectrais é construído da seguinte forma: duas das dimensões são referentes à localização do pixel; e a terceira dimensão é um vetor de assinatura espectral em que cada posição está associada à reflectância para

um determinado comprimento de onda, ou seja, para cada um dos 242 canais espectrais exclusivos emitidos pelo EO-1, o material avaliado terá um nível de reflectância distinto armazenado por meio deste vetor. Portanto, cada pixel representa uma instância do conjunto de dados, os comprimentos de onda são os atributos e os dados são referentes à reflectância para uma determinada radiação emitida.

4.3 Pré-processamento da imagem hiperespectral

Os conjuntos de dados hiperespectrais são superestimados espectralmente e existe muitas informações redundantes presentes (Sahoo et al. (2012)). Portanto, há a necessidade de exploração de métodos de redução de dimensionalidade e extração de membros finais que podem, de forma efetiva, reduzir o volume de dados, de ruídos e auxiliar na separação de misturas espectrais. Essas misturas espectrais são formadas devido à baixa resolução espacial do sensor Hyperion e faz com que os espectros de diferentes substâncias subjacentes sejam combinados em um único pixel.

O primeiro passo é a redução de dimensionalidade, que além de promover um processamento mais rápido dos dados, permite a remoção de bandas com alto teor de ruído ou mesmo aquelas que apresentam dados ausentes.

A necessidade de identificação e remoção de bandas ruins acontece devido a quatro razões. A primeira delas é que existem regiões do espectro que não são calibradas e/ou não possuem dados associados como por exemplo o identificado na banda 71 se comparado com a banda 38 na Figura 4.

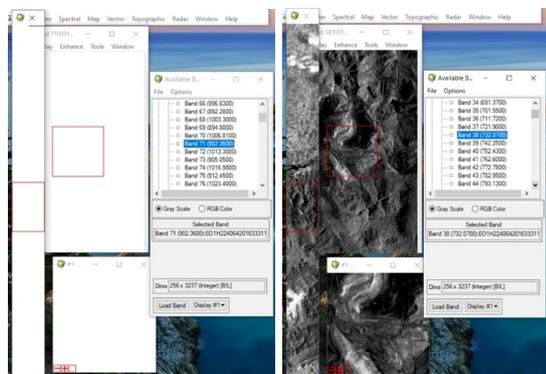


Figura 4. Exemplo de bandas com dados faltantes e bandas com dados completos, respectivamente.

A segunda é por causa da existência de regiões de sobreposição entre os dois espectrômetros do Hyperion, nestas zonas os dados também são ausentes. O terceiro motivo é devido ao fato de que existem regiões do espectro eletromagnético em que o vapor de água encontrado na atmosfera absorve toda a energia incidente, representando, portanto, faixas de bandas em que a reflectância é baixa ou nula. Por fim, algumas das bandas quando analisadas separadamente não apresentam dados por nenhum motivo específico e, por esta razão, também devem ser removidas. A Tabela 1 resume todas as bandas que foram removidas da imagem hiperespectral analisada neste trabalho e o motivo pelo qual cada uma foi retirada. Das 242 bandas constituintes da HSI original, metade foram retiradas nesta

fase de redução de dimensionalidade restando 121 bandas para o próximo passo do pré-processamento.

Tabela 1. Bandas removidas na fase de pré-processamento.

Bandas removidas	Descrição
1 - 12; 225 - 242 58 - 76	Não são calibradas para o LIR Região de sobreposição entre espectrômetros
120 -132; 162 - 182; 221 - 224	Banda de absorção do vapor de água
133; 135; 136; 157; 183 - 188; 190; 192; 193; 195; 196 - 214; 216	Foram verificadas uma a uma e não possuem dados

O segundo passo é verificar a existência de linhas verticais, ruídos de listra ou pixel anormais em todas as 121 bandas restantes e que devem ser considerados e corrigidos antes do processamento posterior. Os pixels anormais são causados por diferenças de calibração e variações temporais na matriz de detecção do Hyperion e estão sempre na direção vertical da HSI. A Figura 5 representa um exemplo de banda que possui o ruído de listra (Figura 5(a)) e uma outra banda cujo ruído foi suavizado (Figura 5(b)). Para a sua remoção e suavização a radiância de cada um dos pixels anormais é substituída na matriz pela média de seus vizinhos. Esta fase foi realizada com cada uma das imagens que apresentou as listras verticais em prol de eliminar esse ruído da HSI.

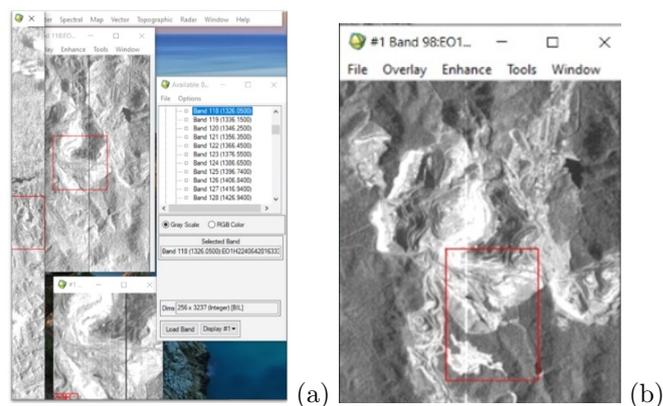


Figura 5. Exemplo de banda com listras verticais ou pixels anormais e após a suavização, respectivamente.

4.4 Análise prévia da imagem hiperespectral

Visualmente é admissível identificar algumas possíveis classes distintas na HSI estudada e que, portanto, espera-se que permaneçam em cluster distintos. Após o pré-processamento, os perfis espectrais de algumas regiões da imagem foram analisadas em prol de distinguir as diferenças na superfície analisada e de verificar a qualidade da fase de pré-processamento. Em específico foi analisado o perfil espectral na frente de lavra da minha onde há minério de ferro, as nuvens e as regiões de mata densa e menos densa.

As Figuras 6 e 7 representam, respectivamente, os perfis espectrais de uma região que acredita-se ser um barragem e a frente de lavra da mina de carajás. Isto porque, os seus perfis espectrais são bem semelhantes. Outro detalhe interessante que é possível observar também é que, após

o pré-processamento os perfis ficam mais contínuos e livre de ruídos. Nas Figuras 6 e 7 o perfil espectral da esquerda representa todos os 242 dados espectrais coletados para o pixel indicado na imagem e o perfil espectral da direita representa todos os 121 dados espectrais coletados para o pixel indicado na imagem pós o pré-processamento.

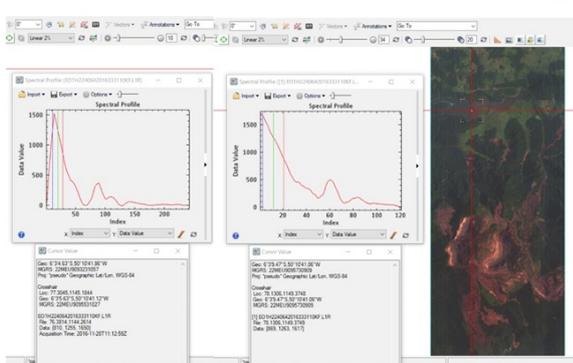


Figura 6. Perfil espectral antes e depois da fase de pré-processamento do que acredita-se ser uma barragem utilizada na exploração do minério de ferro.

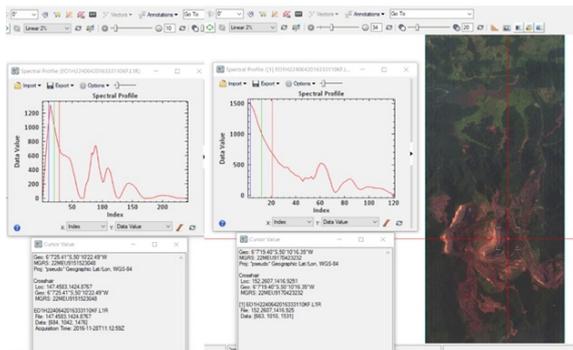


Figura 7. Perfil espectral antes e depois da fase de pré-processamento da frente de lavra de exploração de minério de ferro.

5. RESULTADOS

Os resultados da clusterização obtidos para este trabalho correspondem à aplicação do método K-Means com 4, 5, 6 e 7 clusters. A análise de qualidade dos cluster foi realizada de forma minuciosa e visualmente observando os contornos e o que representa cada elemento da imagem.

De forma intuitiva e observando os diferentes perfis espectrais formados em determinadas áreas como as das Figuras 6 e 7, na HSI da Figura 1 é possível distinguir de forma clara a existência de cinco tipo de elementos: região da mina de Carajás e a evidência da existência de minério de ferro nesta área, bem como na barragem; região de mata mais densa; região de mata menos densa; região de nuvens mais densas; e região de dispersão de nuvens. Assim, os resultados pós aplicação da clusterização por meio do método K-Means dizem respeito ao número de classes que melhor representa esses 5 perfis espectrais distintos identificados na HSI, bem como o que melhor caracteriza os seus contornos.

A Figura 8 mostra o resultado da clusterização utilizando como entrada quatro classes distintas e a Tabela 2 o

número de pixels pertencentes a cada classe identificadas por cores e qual a porcentagem que eles ocupam na imagem. É possível identificar observando a Figura 8 que o número de classes não foi o suficiente para representar o que está na imagem, ainda que já seja possível identificar alguns contornos como os das nuvens.

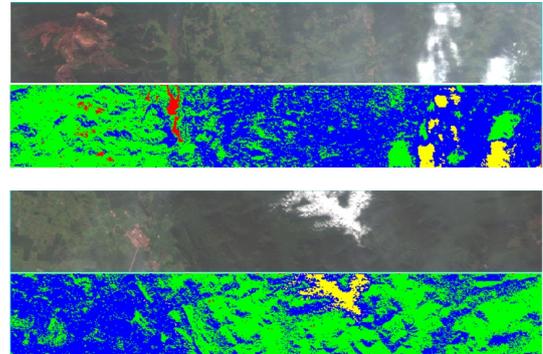


Figura 8. Resultado da clusterização com K-Means e 4 classes.

Tabela 2. Número de pixels por classe para K-Means com 4 clusters.

Cor	Número de pixels	Porcentagem
Red	7379	0,89%
Green	374669	45,21%
Blue	423378	51,09%
Yellow	23246	2,81%

A Figura 9 mostra o resultado da clusterização utilizando como entrada cinco classes distintas e a Tabela 3 o número de pixels pertencentes a cada classe identificadas por cores e qual a porcentagem que eles ocupam na imagem. É possível identificar observando na Figura 9 que o número de classes começa a representar bem a imagem, mas ainda é insuficiente para identificação visual clara de alguns contornos aparentes da imagem. Da mesma forma que na Figura 8 contornos mais evidentes como o das nuvens ficam mais aparentes.

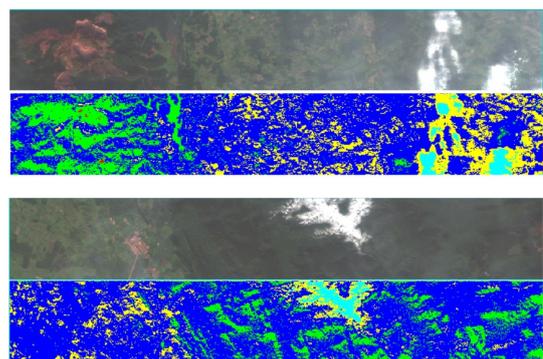


Figura 9. Resultado da clusterização com K-Means e 5 classes.

A Figura 10 mostra o resultado da clusterização utilizando como entrada seis classes distintas e a Tabela 4 o número de pixels pertencentes a cada classe identificadas por cores e qual a porcentagem que eles ocupam na imagem. É possível identificar observando na Figura 10 que o número de classes começa a representa bem os contornos que podem ser identificados visualmente na HSI. O processo

Tabela 3. Número de pixels por classe para K-Means com 5 clusters.

Cor	Número de pixels	Porcentagem
	991	0,12%
	128404	15,50%
	563998	68,06%
	115847	13,98%
	19432	2,34%

de clusterização coloca no mesmo grupo elementos como a cava da mina e a barragem e consegue distinguir bem o que é mata mais densa do que é uma região de mata mais dispersa.

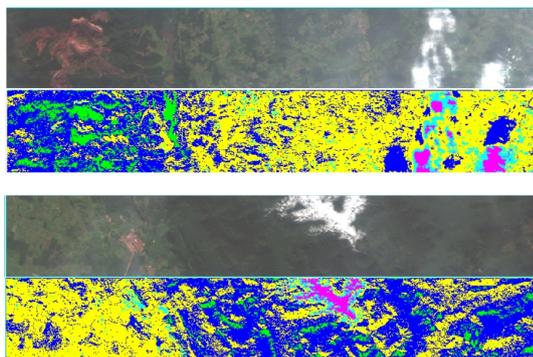


Figura 10. Resultado da clusterização com K-Means e 6 classes.

Tabela 4. Número de pixels por classe para K-Means com 6 clusters.

Cor	Número de pixels	Porcentagem
	493	0,06%
	55715	6,72%
	325840	39,32%
	393050	47,43%
	36118	4,36%
	17456	2,11%

A Figura 11 mostra o resultado da clusterização utilizando como entrada sete classes distintas e a Tabela 5 o número de pixels pertencentes a cada classe identificadas por cores e qual a porcentagem que eles ocupam na imagem. É possível identificar observando na Figura 11 que o número de classes maior não representa tão bem os elementos de superfície constituintes da HSI como a com seis clusters, já que algumas formas antes bem definidas, se perdem.

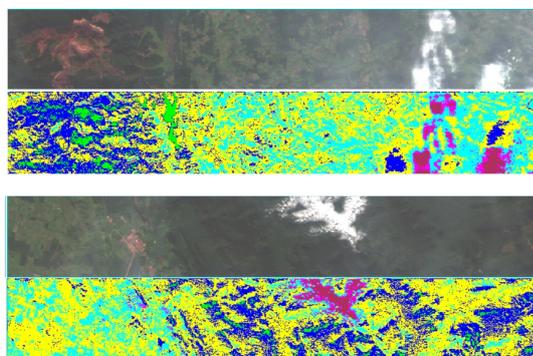


Figura 11. Resultado da clusterização com K-Means e 7 classes.

Tabela 5. Número de pixels por classe para K-Means com 7 clusters.

Cor	Número de pixels	Porcentagem
	435	0,05%
	29740	3,59%
	168600	20,35%
	406395	49,04%
	188199	22,71%
	19161	2,31%
	16142	1,95%

O cluster com 6 classes foi o que, visualmente, conseguiu distinguir melhor os elementos da imagem hiperespectral. Intuitivamente e por meio da análise dos perfis espectrais como expostos nas Figuras 6 e 7, é possível constatar que os seis clusters aparentam ser os descritos pela Tabela 6 em ordem de porcentagem de número de pixels. Em relação ao minério de ferro, a estimativa é que 6,72% da área da imagem seja fonte de minério de ferro (área em verde da Figura 10). Isto corresponde a uma área de aproximadamente $51km^2$, um número razoável em consideração à proporção de área de floresta densa somada com a de área menos densa de aproximadamente $668km^2$.

Tabela 6. Representação de cada uma das classes do K-Means com seis clusters.

Cor	Descrição	Porcentagem
	Áreas de vegetação menos densa	47,43%
	Florestas de mata densa	39,32%
	Possíveis fontes de minério de ferro	6,72%
	Áreas de dispersão de núvens	4,36%
	Áreas de maior concentração de núvens	2,11%
	Estão no limiar da imagem	0,06%

6. CONCLUSÃO

Neste trabalho foi apresentado a aplicação de um método clássico de aprendizagem não supervisionada, o K-Means como forma de análise de uma imagem hiperespectral. A imagem foi analisada para reconhecimento e identificação de depósitos de minério de ferro no Brasil, mais especificamente em uma imagem hiperespectral que inclui a mina de Carajás no Pará. A escolha desta região em específico é estratégica por ser uma área de exploração de minério de ferro que, por consequência, vai refletir o perfil espectral do minério de ferro na região da mina. Além do fato de que a aprendizagem realizada neste trabalho precisa ser não supervisionada em função da inviabilidade de coleta de amostras locais e análise espectral laboratorial. Para tal finalidade, o software ENVI foi utilizado.

Na fase de pré-processamento 121 bandas das 242 disponível foram excluídas da HSI. Isto desempenhou um papel importante na clusterização e foi possível perceber claramente a diminuição de ruídos na imagem e nos perfis espectrais.

Os ensaios com diversos clusters demonstram o quão é importante para o K-Means esta definição inicial do número de classes. Os resultados, ainda que preliminares e, em sua grande maioria, analisados de forma intuitiva mostram que é possível identificar possíveis fontes de exploração mineral utilizando a metodologia proposta. Assim, o cluster com 6 classes foi o que, visualmente, conseguiu distinguir melhor

os elementos da imagem hiperespectral. Em relação ao minério de ferro, a estimativa é que 6,72% da área da imagem seja fonte de minério de ferro (área em verde da Figura 10). Isto corresponde a uma área de aproximadamente 51km^2 , um número razoável em consideração à proporção de área de floresta densa somada com a de área menos densa de aproximadamente 668km^2 .

Para trabalhos futuros pretende-se comparar o método K-means com algoritmos de clusterização equivalentes, como o *Fuzzy C-means* ou FCM e a Rede SOM ou *self-organizing map* para melhor avaliar o método escolhido. Além de realizar ensaios laboratoriais acerca do perfil espectral de alguns tipos minérios de ferro em prol de realizar uma abordagem de classificação supervisionada a ser comparada com a proposta neste trabalho.

AGRADECIMENTOS

Os autores agradecem o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); Vale SA; e Departamento de Ciências e Computação da Universidade Federal de Ouro Preto, Programa de pós-graduação em Ciências da Computação.

REFERÊNCIAS

- Alkhatib, M.Q. and Velez-Reyes, M. (2019). Improved spatial-spectral superpixel hyperspectral unmixing. *Remote Sensing*, 11(20), 2374.
- Campbell, J.B. and Wynne, R.H. (2011). *Introduction to remote sensing*. Guilford Press.
- Gupta, P. and Venkatesan, M. (2020). Mineral identification using unsupervised classification from hyperspectral data. In *Emerging Research in Data Engineering Systems and Computer Communications*, 259–268. Springer.
- Khurshid, S., Staenz, Sun, L., Neville, R., White, H., Abdou, B., Champagne, C., and Hitchcock, R. (2006). Preprocessing of eo-1 hyperion data. *Canadian Journal of Remote Sensing*, 84–97.
- Mukherjee, A., Velez-Reyes, M., and Roysam, B. (2009). Interest points for hyperspectral image data. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3), 748–760.
- Patteti, S., Samanta, B., and Chakravarty, D. (2015). Design of a feature-tuned ann model based on bulk rock-derived mineral spectra for endmember classification of a hyperspectral image from an iron ore deposit. *International Journal of Remote Sensing*, 36(8), 2037–2062.
- Sahoo, R., Pargol, S., Govil, V., Pradhan, S., and Gupta, V. (2012). *Hyperspectral Image Processing using ENVI*.
- Shaik, I., Begum, S., Nagamani, P., and Kayet, N. (2021). Characterization and mapping of hematite ore mineral classes using hyperspectral remote sensing technique: a case study from bailadila iron ore mining region. *SN Applied Sciences*, 3(2), 1–13.
- United States Geological Survey (2021). United states geological survey - earthexplorer. Disponível em: <https://earthexplorer.usgs.gov/>. Acesso em: 21 outubro 2021.