



João Lucas da Conceição de Barros

**Utilização de Veículos Aéreos Não Tripulados e Aprendizagem de Máquina
para Classificação Litológica Automática em Frente de Lavra**

Porto Alegre

31 de Agosto de 2024

João Lucas da Conceição de Barros

**Utilização de Veículos Aéreos Não Tripulados e Aprendizagem de Máquina
para Classificação Litológica Automática em Frente de Lavra**

Dissertação apresentada junto ao Programa de Pós-Graduação em Engenharia de Minas, Materiais e Metalúrgica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, para obtenção do título de Mestre em Engenharia

Orientador: Diego Machado Marques

Porto Alegre

2024

DEDICATÓRIA

Dedico esse trabalho à minha mãe que me deu todo o suporte necessário, financeiro e emocional, para que eu pudesse realizar o sonho de ser um mestre em engenharia.

Agradecimentos

Primeiramente gostaria de agradecer a Deus por me conceder saúde para me desafiar e para expandir os meus horizontes de conhecimento.

A todos os meus familiares e amigos que indiretamente tiveram expressiva colaboração com essa realização.

Aproveito para agradecer ao meu orientador Diego Machado Marques por ter me dado um voto de confiança e me permitido ser orientado ao longo do meu percurso, em todo o mestrado. Obrigado por me instigar, direcionar e ter sido empático durante essa trajetória.

Ao professor Átilla Leães Rodrigues pela colaboração e direcionamento ao longo da construção dessa pesquisa.

Ao João Pedro Lague pelos ensinamentos e auxílios com os *scripts* desenvolvidos nesse desenvolvimento.

À companhia Vale, em especial ao time de Topografia de Carajás, em nome de Fredson Ponte, pela disponibilização de informações utilizadas nesse trabalho.

Aos meus amigos de curso Michael Will Santos e Luciana Maia pela cumplicidade ao longo de algumas disciplinas.

A todos os professores da PPGE3M, por toda dedicação e esforço em entregar um trabalho com excelência e por elevarem o patamar dessa instituição e desse curso.

Muito obrigado!

*“Because nothing grows when it is dark.
In spite of all my fears, I can see it all so clear.”
Of Monsters and Men.*

RESUMO

Nos últimos anos, a adoção de Veículos Aéreos Não Tripulados (VANTs) na indústria de mineração tem ganhado destaque, particularmente em atividades de planejamento de mina. O mapeamento litológico, essencial para o sucesso do planejamento de lavra, depende diretamente da precisão na classificação das frentes de lavra, o que determina tanto o desenvolvimento da mina quanto a alocação de equipamentos específicos. Apesar do avanço em pesquisas sobre a aplicação de VANTs para a classificação litológica, a tecnologia ainda é considerada emergente, necessitando de estudos detalhados e adaptados para cada contexto mineral. Este trabalho visa explorar o potencial da Aprendizagem de Máquina aplicada a imagens capturadas por VANTs no Complexo Mineral de Carajás, focando na extração de minério de ferro, para aprimorar a classificação litológica. A pesquisa testou algoritmos de ponta, como *Support Vector Machine (SVM)* nas variantes Linear e Radial, *Random Forest* e *Gradient Boosting*, aplicados a sinais *RGB (Red, Green e Blue)* decompostos das imagens. Utilizou-se técnicas de agrupamento para tratar os dados. Os resultados demonstraram alta confiabilidade e evidenciaram a eficácia das técnicas de Aprendizagem de Máquina na otimização do processo de mapeamento de minas. Este estudo não apenas reforça a aplicabilidade dos VANTs no setor minerário, mas também abre caminho para futuras pesquisas focadas na integração de novas tecnologias ao planejamento e desenvolvimento de minas, potencializando a precisão e eficiência operacional.

Palavras-chave: Classificação Litológica; Aprendizagem de Máquina; Veículo Aéreo Não-Tripulado; *RGB*.

ABSTRACT

In recent years, the adoption of Unmanned Aerial Vehicles (UAVs) in the mining industry has gained prominence, particularly in mine planning activities. Lithological mapping, essential for the success of mining planning, directly depends on the accuracy in the classification of mining faces, which determines both the development of the mine and allocation of specific equipment. Despite advances in research on the application of UAVs for lithological classification, the technology is still considered emerging, requiring detailed studies adapted to each mineral context. This work aims to explore the potential of Machine Learning applied to images captured by UAVs in Carajas' Complex, focusing on the extraction of iron ore, to improve lithological classification. The research tested cutting-edge algorithms, such as Support Vector Machine (SVM) in Linear and Radial variants, Random Forest and Gradient Boosting, applied to RGB signals decomposed from images. Clustering techniques were used to process the data. The results demonstrated high accuracy and highlighted the effectiveness of Machine Learning techniques in optimizing the mine mapping process. This study not only reinforces the utilization of UAVs in the mining sector, but also paves the way for future research focused on the integration of new technologies into mine planning and development, enhancing precision and operational efficiency.

Keywords: *Lithological Classification; Machine Learning; Unmanned Aerial Vehicles (UAVs); RGB.*

Lista de Ilustrações

Figura 1.1: Fluxograma de Etapas de Trabalho.....	17
Figura 2.1: Espectro Eletromagnético.	22
Figura 2.2: Árvore de Decisão de Classificação de Investimentos.	30
Figura 2.3: Árvores de Decisão Originárias da Tabela 2-3.	31
Figura 2.4: Emprego do modelo <i>KNN</i> para $k = 3$	33
Figura 2.5 - Hiperplano com Margem Máxima (a) e Hiperplano com Margem Menor (b).	34
Figura 2.6: Transformação do conjunto de dados no espaço de entrada(a) para um novo espaço (b).	35
Figura 2.7: Validação Cruzada com 15 <i>Folds</i>	36
Figura 2.8: Diferença entre o particionamento de validação cruzada convencional e espacial.	37
Figura 3.1: Imagem Aérea da Mina de N4E – Cava 2.	39
Figura 3.2: Mapa Província Mineral de Carajás.	40
Figura 3.3: Mapa Geológico – Província Mineral de Carajás.	41
Figura 3.4: Fotografia na frente de Lavra em Estudo.	43
Figura 3.5: Nuvem de pontos densa da frente de lavra, gerada a partir de imagens de Drone.	44
Figura 3.6: Escala R, G e B.	45
Figura 3.7: Classificação Litológica em grupos pertencentes a classes litológicas bem definidas.	46
Figura 3.8: Classes litológicas pertencentes a zonas de contatos ou zonas de interseção entre mais de um litotipo.	47
Figura 3.9: Esquema mostrando o raio de busca de um centroide.	48
Figura 3.10: Histogramas de classes Hematita e Jaspilito e canais R, G e B.	49
Figura 3.11: Histogramas com frequências R, G e B.	50
Figura 3.12: Centroide “capturando” respectivamente os dados de 10 e 20 vizinhos mais próximos a ele.	50
Figura 3.13: Precisão por número de vizinhos para áreas preferenciais (a) e zonas de contato (b).	52
Figura 3.14: F1 por número de vizinhos para áreas preferenciais (a) e zonas de contato (b).	52
Figura 3.15: Precisão por Número de Vizinhos para respectivamente sub amostragem de 35% (a) e 20% (b).	53

Figura 3.16: Precisão por Número de Vizinhos para respectivamente sub amostragem de 35% (a) e 20% (b).	54
Figura 3.17: Revocação por Número de Vizinhos para respectivamente 15 e 45 canais.	55
Figura 3.18: Matriz de Confusão – <i>Random Forest</i> (20% de amostragem de centros e 30 vizinhos mais próximos).	56
Figura 3.19: Matriz de Confusão – <i>Gradient Boost</i> (20% de amostragem de centros e 30 vizinhos mais próximos).	57
Figura 3.20: Modelo de Pontos Classificado - <i>Random Forest</i> .	58
Figura 3.21: Nuvem de Pontos gerada por imagens de VANT.	58
Figura 3.22: Modelo de Pontos Classificado - SVM.	59
Figura 3.23: Validação Cruzada Espacial – <i>Random Forest</i> – <i>Recall Score</i> .	60

SUMÁRIO

Abstract	8
1. INTRODUÇÃO	14
1.1 META DA DISSERTAÇÃO	16
1.2 OBJETIVOS ESPECÍFICOS	16
1.3 ETAPAS DE TRABALHO	17
1.4 ORGANIZAÇÃO DA DISSERTAÇÃO	17
2. REVISÃO BIBLIOGRÁFICA	19
2.1 SENSORIAMENTO REMOTO	20
2.1.1 Fotogrametria	23
2.1.2 Análise Fotoespectral	25
2.1.1 Uso De Veículos Aéreos Não-Tripulados (Vants)	26
2.2 APRENDIZAGEM DE MÁQUINA	28
2.2.1 <i>Random Forest</i>	29
2.2.1 <i>Extreme Gradient Boosting</i>	32
2.2.2 <i>K-nearest Neighbour</i>	32
2.2.3 <i>Support Vector Machine</i>	33
2.2.4 Indicadores de Desempenho e Validação Cruzada Espacial	35
3. ESTUDO DE CASO	38
3.1 ÁREA DE ESTUDO	39
3.2 METODOLOGIA	43
3.2.1 Aquisição de Dados	43
3.2.2 Processamento de Dados	45

3.2.3	Geração e Avaliação do Modelo.....	51
3.3	RESULTADOS E DISCUSSÃO.....	51
4.	CONCLUSÃO	61
5.	REFERÊNCIAS	63

1. INTRODUÇÃO

A crescente adoção de Veículos Aéreos Não Tripulados (VANTs), em geociências, demonstra uma integração eficaz entre avanços teóricos e práticas operacionais. Esses VANTs têm ganhado destaque, especialmente no planejamento de minas, à luz da agilidade necessária para acompanhar a expansão dinâmica da lavra (SMITH; JOHNSON, 2021). O grande tempo necessário para os tradicionais mapeamentos de campo acentua a relevância desses dispositivos, desempenhando um papel essencial na rotina mineradora ao mesmo tempo em que reduzem o risco operacional, minimizando a exposição dos colaboradores a situações perigosas (BROWN; ROTHEFORD e IANNACCHIONE, 2019).

Essa aplicação estratégica de VANTs reflete a aplicabilidade prática das teorias modernas, alinhando-se com os princípios propostos por Lee e Chen (2018) sobre a convergência bem-sucedida entre tecnologia e operações industriais. A convergência dessas abordagens teóricas com a indústria de mineração evidencia uma sinergia entre inovação tecnológica e otimização de processos, resultando em maior eficiência e segurança no setor.

Recentemente, avanços na tecnologia de VANTs têm impulsionado significativamente a capacidade de captura ótica, com a adoção de câmeras de alta resolução, e aprimorado a eficácia da análise de dados por meio de melhorias em software e capacidade de processamento (JOHNSON; SMITH, 2022). Essas inovações tecnológicas têm contribuído para aprimorar a qualidade das informações coletadas, ampliando assim as possibilidades de aplicação dos VANTs em diversos setores, incluindo a indústria mineradora (BROWN; ROTHEFORD e WILLIAM, 2020).

No planejamento de mina, a utilização de VANTs tem sido avaliada na classificação litológica de frentes de lavra a céu aberto, o que permite a inserção de dados de forma mais dinâmica ao modelo geológico, o que gera maior precisão aos modelos criados. Segundo Beretta *et al.* (2018), A informação adquirida durante o desenvolvimento da cava é essencial para reduzir a incerteza de adaptar modelos por meio de reconciliação entre o planejamento e a execução. Com o avanço da lavra, novos dados são coletados e, conseqüentemente, cálculos de recursos minerais e reservas de minério aumentam, em acurácia, para fornecer orientação para o planejamento a curto, médio e longo prazos.

De acordo com Senhorinho (2008) o problema em derivar todo um planejamento de lavra baseado num único modelo, está principalmente relacionado ao fato de que este será incapaz de reproduzir a variabilidade intrínseca à realidade do depósito mineralizado. Uma vez que é amplamente reconhecido ser impossível conceber uma apresentação perfeita do depósito mineralizado, tomando-se em conta o fato de que o conhecimento geológico, os dados amostrados e as considerações feitas para a interpretação e avaliação de teores são todas imperfeitas, as decisões tomadas para o planejamento de lavra e sequenciamento também estarão baseadas em dados imperfeitos. Sabendo disso, pode-se usar o uso de análise de incertezas, tentando gerenciar os riscos, ou aumentar a quantidade de informação disponível, mesmo que os dados tenham algum pequeno viés. Sendo assim, para minimizar os efeitos da dificuldade de reprodução da variabilidade intrínseca a um modelo geológico são realizadas amostragens em pó de perfuratriz, classificação em frentes de lavra e reconciliações de pilhas de minério fazem parte de alguns métodos que irão integrar o modelo inicial composto pelos furos de sondagem no refinamento do modelo de recursos.

O mapeamento litológico de superfícies de lavras representa ao planejamento de mina de curto prazo um papel fundamental. Por meio da classificação nas frentes de lavra é possível determinar por onde seguir com a lavra e quais equipamentos serão encaminhados para quais frentes de trabalho. Além disso, é possível cruzar essas informações às dos modelos de médio e longo prazo, de modo a verificar a acurácia das estimativas iniciais e reconciliar o modelo inicialmente gerado às novas informações.

Para Beretta *et al.* (2019), métodos tradicionais de mapeamento de superfície em minas a céu aberto são, principalmente, compostos de medições em campo de feições visíveis e coleta de dados qualitativos. Entretanto, esta tarefa expõe o geólogo às condições atmosféricas e outros tantos riscos, como queda de fragmentos de rochas, equipamentos em movimento, queda da bancada, exposição à poeira e gases etc. Isto pode, também, ser uma tarefa de alto consumo de tempo e industrialmente improdutiva, já que outras operações têm que esperar até que o geólogo complete seu trabalho antes de retomar as atividades.

A incorporação da Aprendizagem de Máquinas (AM) na indústria de mineração tem impulsionado avanços significativos. Em contextos de veículos e equipamentos autônomos, a utilização de ferramentas de AM desempenha um papel crucial na viabilização da operação remota e autônoma de equipamentos de mineração, atenuando a exposição dos trabalhadores a ambientes perigosos (CHEN; WANG e ZHANG, 2019). Além disso, nas operações convencionais, a implementação de sensores e dispositivos vestíveis possibilita a coleta de dados relacionados à saúde e bem-estar dos trabalhadores, permitindo a detecção em tempo real de situações perigosas e a emissão de alertas aos trabalhadores ou à equipe de segurança (SMITH; JOHNSON, 2021).

Mesmo que já tenham sido desenvolvidos alguns trabalhos tratando da aplicação de VANT à classificação litológica, essa tecnologia é recente, de modo que existe a necessidade de estudos aplicados a cada caso. No caso do minério de ferro, e mais especificamente da região de Carajás, é necessário entender se as particularidades de litotipos nessa região, permitem o emprego dessa tecnologia com a acurácia esperada.

1.1 META DA DISSERTAÇÃO

A meta desta dissertação de mestrado é aprimorar a análise de imagens capturadas por Veículos Aéreos Não Tripulados (VANTs) no setor de mineração de minério de ferro, com enfoque específico no Complexo Mineral de Carajás. Pretende-se implementar e avaliar técnicas avançadas de Aprendizado de Máquina supervisionado, como *Support Vector Machines*, *Random Forest* e *Gradient Boosting*, para a identificação litológica nas frentes de lavra. O propósito é explorar a eficácia desses métodos computacionais na melhoria da precisão e eficiência do mapeamento litológico, contribuindo para a otimização dos processos de planejamento e operação em mineração.

1.2 OBJETIVOS ESPECÍFICOS

Para atingir tal meta, alguns objetivos específicos foram traçados:

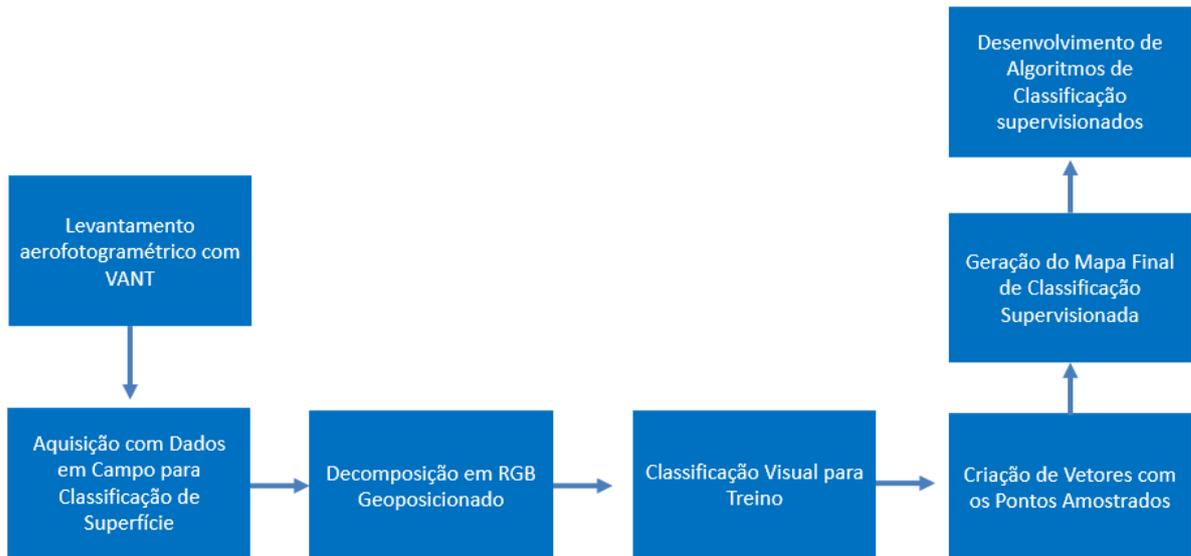
- **Desenvolver um modelo tridimensional da face de exploração mineral** utilizando dados capturados por VANTs, para proporcionar uma compreensão detalhada da topografia e morfologia da área de interesse, facilitando a análise litológica e a tomada de decisões estratégicas no planejamento de mina.

- **Realizar a decomposição espectral multivariada dos dados aerofotogramétricos**, para extrair características espectrais distintas das imagens que permitam a diferenciação entre as várias unidades litológicas presentes no Complexo Mineral de Carajás. Este processo visa melhorar a precisão na identificação de materiais e na classificação geológica.
- **Aplicar e avaliar métodos de Aprendizado de Máquina supervisionado (como *Support Vector Machines*, *Random Forest* e *Gradient Boosting*)** para a identificação semiautomática de unidades geológicas a partir das características espectrais e morfológicas derivadas dos dados de VANT. O objetivo é desenvolver um modelo preditivo eficaz que auxilie na classificação litológica rápida e precisa, reduzindo a necessidade de análises manuais extensivas e sujeitas a erros.

1.3 ETAPAS DE TRABALHO

Para atingimento da meta e objetivos propostos, serão seguidas as seguintes etapas, demonstradas no fluxograma abaixo:

Figura 1.1: Fluxograma de Etapas de Trabalho.



Fonte: O próprio autor (2024).

1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

Após a introdução, os capítulos dessa dissertação são estruturados da seguinte forma:

O **Capítulo 2** apresenta brevemente uma revisão bibliográfica sobre sensoriamento remoto, uso de VANTs e Aprendizagem de Máquinas;

O **Capítulo 3** revela o estudo de caso, detalhando as características da área de estudo, metodologia proposta e os resultados obtidos;

O **Capítulo 4** expõe as conclusões e recomendações para trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

Na prospecção e pesquisa mineral, o avanço da fotogrametria tem desempenhado um papel crucial, estabelecendo-se como uma técnica imprescindível no reconhecimento de padrões litológicos e na caracterização topográfica. A fotogrametria, por meio da utilização de imagens aéreas ou de satélite, permite a reconstrução de espaços tridimensionais, proporcionando um mapeamento preciso, o qual é fundamental para o entendimento geológico detalhado de uma região. Associa-se frequentemente a fotogrametria às leituras de *RGB* oriundas de câmeras convencionais. Contudo, seu escopo se expande para a integração de dados hiperespectrais, elevando significativamente o nível de detalhe e precisão das análises.

A captura de imagens hiperespectrais, com suas centenas de bandas espectrais, oferece uma multidimensionalidade de informações que é intrinsecamente complexa. Esta complexidade encontra-se na capacidade de diferenciar rochas e minerais com base em suas propriedades espectrais únicas. Comprimentos de onda específicos refletidos ou emitidos por diferentes materiais podem ser discriminados e utilizados na identificação e classificação de alvos geológicos.

Em meio a essa riqueza de dados, o Aprendizado de Máquina (AM) emerge como uma ferramenta valiosa, capaz de gerir e interpretar a natureza multidimensional das informações espectrais. A utilização de algoritmos de AM facilita a identificação de padrões complexos e sutis que muitas vezes são imperceptíveis às técnicas de análise tradicionais. Por meio de métodos supervisionados, modelos preditivos podem ser treinados com conjuntos de dados rotulados, melhorando a acurácia na classificação dos tipos litológicos.

Adicionalmente, o sensoriamento remoto serve como uma extensão natural da fotogrametria no campo da geociência. Instrumentos de sensoriamento remoto, que registram dados de Radiação Eletromagnética (REM), podem revelar alterações minerais e texturais nas rochas, permitindo a inferência de condições geológicas passadas e presentes. A combinação dessas tecnologias, aliada ao Aprendizado de Máquina, amplifica o entendimento e permite a otimização dos esforços de prospecção mineral, proporcionando um método não invasivo para a exploração de recursos minerais.

Neste capítulo, a revisão bibliográfica contemplará os avanços recentes na aplicação da fotogrametria e do sensoriamento remoto em geociências, bem como a implementação de estratégias de Aprendizado de Máquina para a interpretação de dados espectrais, destacando seu impacto significativo na eficiência da prospecção mineral e na pesquisa geológica.

2.1 SENSORIAMENTO REMOTO

O sensoriamento remoto é definido como a prática e a ciência de adquirir informações sobre um objeto, área ou fenômeno sem estar em contato físico direto com ele. Historicamente, esta técnica tem sido empregada através de dispositivos montados em plataformas aéreas ou espaciais, que capturam dados através de sensores. Esses sensores são projetados para registrar as radiações refletidas ou emitidas pelos objetos observados em diferentes comprimentos de onda. Os dados coletados são posteriormente processados e interpretados para a aplicação em diversas áreas, como a geologia, meteorologia, agricultura e gestão de recursos naturais. A evolução tecnológica, sobretudo na miniaturização de sensores e no avanço de algoritmos de processamento de dados, tem expandido significativamente o escopo e a precisão do sensoriamento remoto.

A coleta de informações pode ocorrer diretamente no campo, ou de forma remota, a determinada distância do projeto do objeto. Independentemente do quão cuidadoso seja o trabalho de amostragem de dados, erros podem ser introduzidos durante o processo de coletas.

De acordo com Lillesand, Kiefer e Chipman (2004) sensoriamento remoto é tecnologia de obtenção de informações sobre um objeto, área ou fenômeno, através da análise de dados adquiridos por um sensor que não está em contato com o objeto, área com fenômeno.

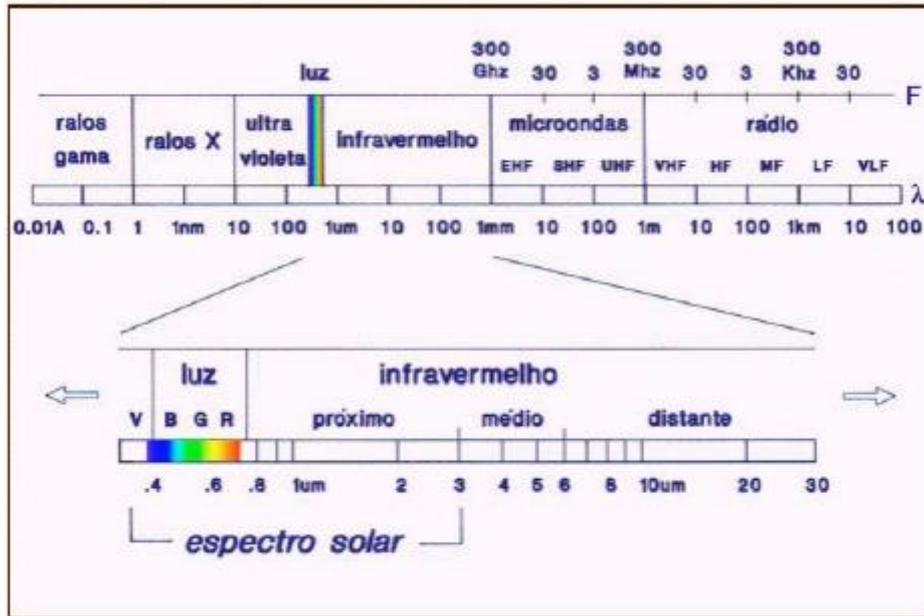
A maioria dos instrumentos de sensoriamento remoto registram a REM (Radiação Eletromagnética) que se desloca a uma velocidade de $3 \times 10^8 \text{ m/s}$ a partir da fonte diretamente através do vácuo ou, indiretamente, por reflexão ou rerradiação para o sensor. A REM representa um canal de comunicação muito eficiente e em alta velocidade entre o sensor e o fenômeno remoto. Mudanças na quantidade ou propriedade da REM tornam-se, pela detecção pelo sensor, uma valiosa fonte de dados para interpretar importantes propriedades do fenômeno (como temperatura e cor, por exemplo). Outros tipos de campos de forças podem ser usados em lugar da REM, tais como ondas acústicas (sonar) (DARTNELL; GARDNER 2004)

Toda radiação eletromagnética tem propagação ao longo do espaço em formato de ondas. A velocidade de propagação dessas ondas, em metros por segundo, é diretamente correlacionada ao comprimento de onda λ , em metros, e à frequência ν , em Hertz (ciclos por segundo), de acordo com a equação abaixo:

$$C = \lambda\nu$$

O espectro eletromagnético (Figura 2.1) representa, de maneira organizada, os diversos tipos de radiação eletromagnética, a depender dos limites de comprimentos de ondas, podendo ser mais curtos (Radiação gamas e raio X) ou maiores (microondas e ondas de rádio).

Figura 2.1: Espectro Eletromagnético.



Fonte: Da Silva, 2006.

A depender de suas características específicas, algumas bandas do espectro eletromagnético apresentam denominações especiais, de acordo com a tabela a seguir:

Tabela 2-1: Denominações Especiais - Bandas Espectro Eletromagnético.

Espectro	Descrição
Espectro óptico	Refere-se à região do espectro eletromagnético que compreende as energias que podem ser coletadas por sistemas ópticos (ultravioleta, visível e infravermelho).
Espectro visível	Refere-se ao conjunto das energias eletromagnéticas percebido pelo sistema visual humano, também denominado de luz.
Espectro solar	Região espectral que abrange a radiação eletromagnética emitida pelo Sol e responsável por cerca de 99% da energia solar que atinge a Terra; concentra-se na faixa de 0,28 a 3 μm.
Espectro termal	Conjunto de radiações eletromagnéticas emitidas pelos objetos terrestres. Encontram-se nos intervalos espectrais do infravermelho médio ao distante.

Fonte: adaptada de Da Silva, 2006.

Um dos métodos de sensoriamento remoto que tem sido amplamente utilizado, nos últimos anos, é a fotogrametria.

2.1.1 Fotogrametria

Fotogrametria é a ciência de obter informação confiável sobre as propriedades de superfícies e objetos sem contato físico com esses objetos, além de medir e interpretar essas informações. O nome fotogrametria deriva de três palavras em grego *phos* ou *phot* que significa luz, *gramma* que significa algo desenhado, e *metrein*, o nome de medida (SCHENK; 2005).

Para Aber e Ries (2010) fotogrametria é uma técnica de medição por coordenadas tridimensionais que usa fotografias como meio fundamental para metrologia ou medições, no geral. O princípio fundamental usado na fotogrametria é a triangulação. Ao tirar fotografias de pelo menos dois locais diferentes, as chamadas “linhas de visão” podem ser desenvolvidas de cada câmera para pontos no objeto. Essas linhas de visão, às vezes chamadas de raios devido à sua natureza ótica, são interseccionadas matematicamente para produzir as coordenadas tridimensionais dos pontos de interesse.

Fotogrametria pode ser definida como a ciência ou arte de determinar características qualitativas e quantitativas de objetos através de imagens geradas em fotografias, seja física ou digital. Objetos são identificados e qualitativamente descritos durante a observação fotográfica das características das imagens como forma, padrão, tonalidade e textura (ENTERPRISES, 2009).

Para facilitar o entendimento sobre fotogrametria, na visão de Schenk (2005) os procedimentos de fotogrametria são considerados uma caixa preta. O *input* é caracterizado por obter informação confiável através do processo de recordar padrões de radiação de energia eletromagnéticas, predominantemente na forma de imagens fotográficas. O *output*, na outra mão, contempla produtos fotogramétricos gerados na caixa preta.

Tabela 2-2: Ferramentas, Procedimentos e Produtos Fotogramétricos.

Aquisição de Dados	Procedimentos Fotogramétricos	Produtos Fotogramétricos
		Produtos Fotográficos
		Alargamentos / Reduções
		Retificações
	Retificadora	
Câmeras Fotográficas	Projetor de Ortofoto	Ortofotos
	Comparador	Pontos
		(DEMs, perfis, superfícies)
Scanner	Estereógrafo	Mapas
	Pilotadora Análítica	
		Mapas Topográficos
Sensor -> Imagem Digital	Computador	Mapas Especiais

Fonte: Tabela adaptada de Schenk, 2005.

A Tabela 2-2 descreve algumas das ferramentas utilizadas para a aquisição de dados, que por meio de procedimentos, poderão gerar diferentes produtos fotogramétricos como mapas topográficos ou nuvem de pontos. Os procedimentos variam de acordo com a ferramenta escolhida e o tipo de produto desejado. Por exemplo, podem-se utilizar retificadoras para aplicar correções geométricas em imagens capturadas, melhorando sua precisão para usos como mapeamento. Além disso, estereoscópios são instrumentos que permitem a visualização de imagens em alta resolução com efeito tridimensional, facilitando a interpretação e o levantamento de medidas precisas a partir de pares de fotografias aéreas ou de satélites.

A fotogrametria é uma opção mais acessível em comparação com tecnologias como varreduras a laser, devido à redução de custos, permitindo o uso de câmeras mais simples (KATZ; FRIESS, 2014). Sua portabilidade é uma vantagem significativa, já que as câmeras digitais são fáceis de transportar para o campo, ao contrário dos scanners a laser, que são mais volumosos e exigem fontes de energia externas. Além disso, a fotogrametria otimiza a gestão do tempo, pois o processo de processamento de imagem é mais rápido do que o das varreduras a laser, resultando em economia de tempo, no geral. (WROBEL; BIGGS; HAIR, 2019).

Embora a fotogrametria seja uma técnica versátil, apresenta desafios. Requer habilidades específicas para operar softwares especializados, (ANDERSON, 1982), enfrenta obstáculos ambientais como topografia e iluminação, e requer a estabilidade do objeto de estudo (UNHAMMER, 2016). A qualidade da iluminação é crucial, especialmente em locais de difícil acesso, como cavernas e abrigos cobertos por rochas (ROBEDIZO, 2016), além disso a técnica pode apresentar limitações de resolução (WROBEL; BIGGS; HAIR, 2019).

É essencial reconhecer que, apesar de tais restrições potenciais, a fotogrametria é capaz de alcançar precisão sub milimétrica. Este nível de detalhe é muitas vezes suficiente para uma ampla gama de aplicações práticas e pode ser obtido sem a necessidade de equipamentos pesados, a preocupação com fontes de energia externas, ou a dependência de instalações laboratoriais especializadas. Deste modo, a fotogrametria emerge como uma técnica altamente adaptável e valiosa, especialmente em ambientes desafiadores ou onde a mobilidade e a flexibilidade são essenciais (WROBEL; BIGGS; HAIR, 2019).

2.1.2 Análise Fotoespectral

A cor desempenha um papel fundamental no sensoriamento remoto, sendo o principal alvo das medições realizadas por sensores físicos sobre a superfície terrestre e sua cobertura. Esta tecnologia tem se concentrado historicamente na análise de áreas extensas, como formações agrícolas ou características geológicas, onde a cor auxilia na identificação e classificação de grandes entidades.

Diferentes modelos de imagem, incluindo binário, em tons de cinza, colorido e hiperespectral, possuem características distintas. Em imagens binárias, pixels representam valores de 1 bit: 0 para preto e 1 para branco. Imagens em escala de cinza utilizam inteiros de 8 ou 16 bits, abrangendo 256 tonalidades de cinza, onde 0 indica preto e 255, branco. Imagens coloridas, ou *RGB*, definem cada pixel por valores de vermelho, verde e azul, permitindo até 16,777,216 combinações de cores. A fotogrametria, ao analisar esses modelos, identifica similaridades entre imagens para construir malhas 3D. Essa técnica requer imagens detalhadas, ambientes sem reflexos e iluminação uniforme, pois depende da identificação precisa de padrões para mapear pontos no espaço 3D e gerar texturas a partir das imagens originais.

2.1.3 Esteroscopia

A estereoscopia é uma técnica fundamental na reconstrução tridimensional, amplamente aplicada em áreas como a fotogrametria, visão computacional e realidade aumentada. A estereoscopia parada, especificamente, refere-se ao processo de capturar imagens de uma cena ou objeto a partir de diferentes posições fixas, permitindo a criação de um modelo 3D detalhado a partir dessas imagens bidimensionais. Essa técnica é usada para calcular a disparidade entre as imagens e, conseqüentemente, inferir a profundidade e a estrutura tridimensional da cena (SZELISKI, 2022).

O Structure from Motion (SfM) é uma técnica que evoluiu significativamente nos últimos anos, permitindo a reconstrução tridimensional a partir de um conjunto de imagens capturadas de diferentes ângulos enquanto a câmera se move. O SfM é particularmente útil em ambientes onde a captura em movimento é inevitável, como em veículos aéreos não tripulados (VANTs) ou câmeras portáteis. O algoritmo SfM identifica pontos característicos comuns em várias imagens e usa esses pontos para calcular a posição 3D correspondente, resultando em um modelo tridimensional robusto (KNIJNENBURG; KALANTARI; BAIER, 2021).

O conceito de múltiplo estéril continua a ser um desafio significativo na correspondência estereoscópica. Esse fenômeno ocorre quando múltiplos pares de pontos em diferentes imagens correspondem a uma única posição no espaço tridimensional, complicando a reconstrução precisa. Avanços recentes têm focado em métodos de aprendizado profundo que visam melhorar a acurácia na correspondência e reduzir as ambigüidades associadas ao múltiplo estéril (XU et al., 2020).

O processamento de imagens que não ortofotos continua a ser uma área crítica de pesquisa, especialmente em aplicações que envolvem análise de imagens aéreas ou de satélite. Técnicas recentes incluem o uso de redes neurais convolucionais para melhorar o realce de contraste e a segmentação, permitindo a extração de informações mais precisas de imagens que não foram corrigidas geometricamente. Esse tipo de processamento é essencial para a interpretação direta de características da superfície terrestre em aplicações como monitoramento ambiental e planejamento urbano (ZHANG; KANG; LI, 2023).

2.1.4 Uso De Veículos Aéreos Não-Tripulados (Vants)

O mapeamento com VANT vem se mostrando uma ferramenta eficiente e eficaz na modelagem de áreas para diversos fins. Na mineração, em especial, a técnica é utilizada para reconstituir o terreno de maneira bastante fiel, oferecendo suporte à diversos setores da mineração (PERONI, 2017).

A evolução e diversificação dos Veículos Aéreos Não Tripulados (VANTs) têm impulsionado significativamente o campo do Sensoriamento Remoto, particularmente na coleta de dados geográficos e ambientais. Essas aeronaves, que variam em design como as de asa fixa e multirrotores, oferecem vantagens específicas dependendo da escala e do propósito do levantamento. VANTs de asa fixa são preferidos para o mapeamento de vastas áreas, acima de 200ha, devido à sua maior velocidade e autonomia de voo. Por outro lado, multirrotores são valorizados por seu custo mais acessível, facilidade de operação e segurança em manobras de pouso e decolagem, tornando-os ideais para projetos com restrições de espaço ou orçamentárias.

A escolha do sensor embarcado é crucial e deve alinhar-se com o objetivo do levantamento, variando de sensores geofísicos, câmeras termais e multiespectrais, a sistemas LiDAR. No entanto, as câmeras fotográficas permanecem como o sensor mais utilizado, especialmente ajustadas para capturar imagens *RGB*, fundamentais na reconstituição e análise do terreno.

Os VANTs, ou Veículos Aéreos Não Tripulados, são destacados por sua capacidade de voos longos, segurança aprimorada, repetição de missões e redução de custos em comparação com aeronaves tripuladas. Sua evolução tecnológica os torna essenciais para preencher lacunas deixadas por sistemas de detecção por satélite e aeronaves tripuladas no Sensoriamento Remoto. Especificamente na indústria de mineração, a capacidade dos VANTs de coletar dados em alta resolução é revolucionária, permitindo um mapeamento detalhado das frentes de lavra. Isso possibilita uma análise mais precisa do terreno, otimizando o planejamento da extração de recursos minerais e reduzindo a perturbação ambiental. A integração desses dados com técnicas avançadas de análise, como algoritmos de Aprendizado de Máquina, melhora ainda mais a capacidade de previsão e planejamento das operações de mineração, representando um avanço significativo na indústria.

2.2 APRENDIZADO DE MÁQUINA

De acordo com Mohri, Rostamizadeh e Talwakar (2012), o aprendizado de máquina é definido como o uso de métodos computacionais que utilizam a experiência para aprimorar o desempenho ou desenvolver estratégias precisas. Nesse contexto, a experiência refere-se às informações passadas disponíveis para o aprendizado, geralmente na forma de dados eletrônicos que são encontrados e disponibilizados para análise.

Os mesmos autores afirmam que o aprendizado de máquina envolve a criação de algoritmos de previsão eficientes e precisos. Assim como em outras áreas da ciência da computação, a qualidade desses algoritmos é avaliada em termos de sua complexidade de tempo e espaço. No entanto, no campo do aprendizado de máquina, é necessário considerar também a complexidade da amostra para determinar o tamanho necessário da amostra para que o algoritmo seja capaz de aprender uma determinada família de conceitos. De maneira mais ampla, as garantias de aprendizado para um algoritmo, independentemente da complexidade dos conceitos envolvidos, incluem o tamanho da amostra de treinamento.

A aplicação do aprendizado de máquina tem sido mostrada cada vez mais relevante e promissora em diversas áreas do conhecimento. Na indústria, por exemplo, o aprendizado de máquina tem sido amplamente utilizado para aprimorar processos produtivos e reduzir custos. Os algoritmos podem analisar dados provenientes de sensores e máquinas em tempo real, identificando padrões e anomalias que sinalizam a necessidade de manutenção preventiva ou a otimização das interrupções na produção. Isso resulta em maior eficiência operacional, redução de desperdícios e melhoria na qualidade dos produtos.

Na área de mineração, os algoritmos são empregados na roteirização de caminhões fora de estrada, na análise de falhas operacionais por trecho e otimização na frota. Em termos de segurança, eles podem auxiliar na detecção de movimentos que representem riscos e fadiga para os operadores de equipamentos móveis.

O aprendizado de máquina permite que modelos sejam treinados com conjuntos de dados antes de sua implementação. Alguns modelos, caracterizados como modelos *online*, adaptam-se continuamente conforme novos dados são gerados e acessados. Outros, chamados de modelos *offline*, são estáticos após a implementação. A abordagem iterativa dos modelos *online* resulta em melhorias nas associações feitas entre os elementos de dados, incorporando informações não utilizadas durante o treinamento inicial. Os algoritmos *online* refinam constantemente os modelos, processando os dados quase instantaneamente e treinando o sistema para se adaptar às mudanças nos padrões e novas associações nos dados.

Além da distinção entre modelos online e offline, os modelos de aprendizado de máquina podem ser classificados com base na rotulagem das classes mapeadas, sendo categorizados como aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, um algoritmo é treinado com dados previamente rotulados para uma saída específica, permitindo a detecção de padrões e relações entre os dados de entrada e os rótulos de saída. Isso possibilita a produção de resultados de rotulagem precisos ao lidar com novos dados. A principal função do aprendizado supervisionado é interpretar os dados em relação a uma questão específica, sendo comumente utilizado para problemas que envolvem a categorização de conjuntos de dados ou a previsão de comportamentos com base em observações anteriores.

Serão abordados nesse trabalho quatro modelos de aprendizagem de máquina: *Random Forest*, *K-nearest neighbour*, *Support Vector Machine* e *Extreme Gradient Boost*.

2.2.1 *Random Forest*

Pode se dizer que o modelo *Random Forest* é uma extensão do método de Árvore de Decisão, por isso para entendê-lo é fundamental que se compreenda como se desenvolve o modelo embrionário. Árvore de decisão (Figura 2.2: Árvore de Decisão de Classificação de Investimentos.) é um método de classificação que utiliza um padrão de decisão para classificar um conjunto de dados numéricos ou categóricos.

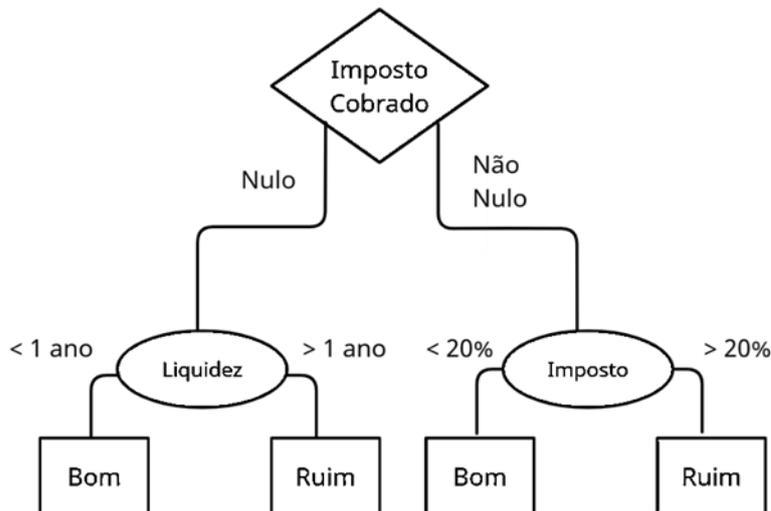
No exemplo a seguir é apresentada uma árvore de decisão utilizada para classificar investimentos como bons ou ruins a partir de algumas premissas. Os dados de treinamento aplicados ao modelo são mostrados na Tabela 2-3.

Tabela 2-3: Dados de Treinamento aplicados ao Exemplo de *Random Forest*.

Risco	Liquidez	Retorno %		Classificação do Investimento
		/ano	Imposto Cobrado	
Alto	Diária	Variável	-	Ruim
Médio	Diária	Variável	-	Bom
Médio	1095 dias	33%	15%	Moderado
Alto	Diária	Variável	-	Excelente
Baixo	100 dias	12%	28%	Bom
Médio	165 dias	15%	28%	Moderado
Baixo	365 dias	19%	23%	Moderado
Baixo	730 dias	26%	15%	Bom

Fonte: O Próprio Autor, 2024.

Figura 2.2: Árvore de Decisão de Classificação de Investimentos.



Fonte: O próprio autor (2024).

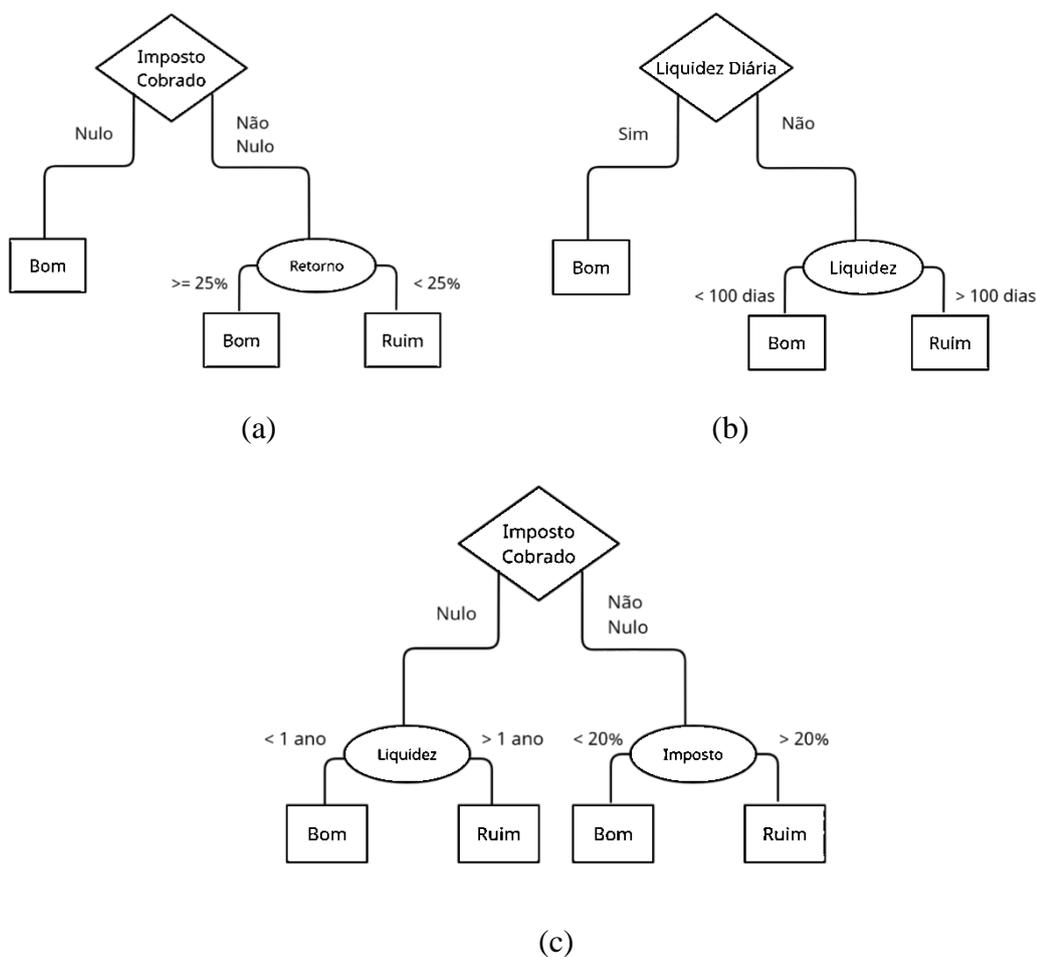
De acordo com Li, R. e Belford, G. (2002), as árvores de decisão são intrinsecamente instáveis, ou seja, pequenas alterações nos dados de entrada podem resultar em grandes mudanças nas partículas finais. Para mitigar essa instabilidade, uma abordagem é a diversificação de árvores, conhecida como *Random Forest*. Esse método seleciona aleatoriamente subconjuntos de árvores para testar os dados e, ao final, gera uma probabilidade de ocorrência com base nos diferentes modelos de árvores avaliadas.

Como exemplo de *Random Forest*, usaremos o mesmo caso anterior de investimentos, para avaliar a classificação do dado da linha número 5 da Tabela 2-3. Para esse dado, os *outputs* de resultados de investimentos diferem, de acordo com a árvore de decisão avaliada. São mostradas três árvores de decisão distintas, para o mesmo problema, na

Figura 2.3: Árvores de Decisão Originárias da .

A primeira delas classifica a proposta de investimento como ruim, já as duas últimas como bons. O *output* de floresta aleatória, nesse caso, seria a classificação de “Bom” com um *score* de classificação de 0,667. Os diferentes conjuntos de características que aparecem em cada árvore indicam que a projeção aleatória do subespaço foi aplicada.

Figura 2.3: Árvores de Decisão Originárias da Tabela 2-3.



Fonte: O próprio autor (2024).

Devido à diversidade de árvores possíveis, a *Random Forest* consegue lidar com valores faltantes sem a necessidade de um pré-processamento complexo. Além disso, ao treinar as árvores, é possível melhorar o desempenho do modelo em classes minoritárias, evitando viés em favor da classe majoritária.

2.2.1 *Extreme Gradient Boosting*

A principal ideia por trás do *Extreme Gradient Boosting* (XGBoost) é construir um conjunto de árvores de decisão de forma sequencial, onde cada árvore é treinada para corrigir os erros cometidos pelas árvores anteriores. Durante o treinamento, o algoritmo atribui pesos aos exemplos de treinamento, dando mais importância aos exemplos que foram classificados incorretamente anteriormente. Dessa forma, o XGBoost concentra seus esforços nas áreas mais difíceis de serem corretamente classificadas e faz com que esses indivíduos sejam submetidos a novos arranjos de dados e a outras iterações que permitam que os tornem assertivos. Ele otimiza o *boosting* sequencial para construir um conjunto de árvores que corrigem erros anteriores, com o objetivo de melhorar a precisão do modelo final.

Segundo Friedman (2002) *Extreme Gradient Boosting* é uma adaptação do algoritmo *Gradient Boosting*, desenvolvido para ser escalonável e rápido, lidando com dados esparsos (CHEN; GUESTRIN, 2016). *Gradient Boosting* constrói modelos aditivos - um conjunto de árvores, ajustando sequencialmente um *weak learner* aos atuais “pseudo” - residuais da árvore anterior por meio dos mínimos quadrados a cada iteração. Os pseudo-residuais são o gradiente da função de perda que está sendo minimizada, com relação aos valores da árvore a cada dado de treinamento avaliado no passo atual. (FRIEDMAN; 2002)

De acordo com Forti (2018) considerando a utilização de árvores de decisão para o ajuste do *Gradient Boosting*, o objetivo de cada árvore de decisão ajustada é minimizar a função de perda, ou seja, minimizar o gradiente da função objetivo do modelo corrente.

2.2.2 *K-nearest Neighbour*

O método de *k-nearest neighbour*, ou K-vizinhos mais próximos (*kNN*), é um método não paramétrico que atribui um objeto desconhecido, x_t , na classe à qual pertence a maioria de seus k vizinhos mais próximos.

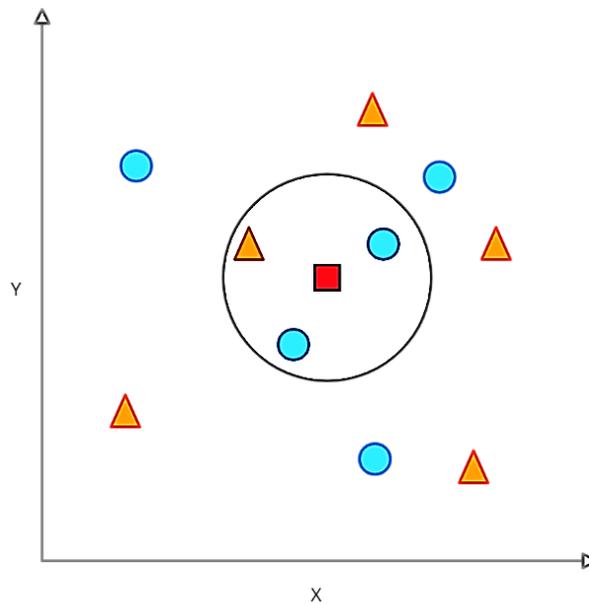
Em outras palavras, o *KNN* calcula todas as distâncias entre x_t e todos os objetos X_i e classifica x_t na classe da maioria dos K objetos mais próximos da vizinhança. A distância euclidiana é a mais utilizada e é calculada de acordo com a seguinte equação:

$$d_{E(x_t, x_i)} = \sqrt{\sum_{j=1}^i (x_{ij} - x_{it})^2}$$

Onde $d_{E(x_t, x_i)}$ é a distância Euclidiana entre o objeto desconhecido, x_t e o objeto de treinamento x_i .

A figura 2.4 ilustra como é realizada a classificação por meio do método *KNN* para $K=3$:

Figura 2.4: Emprego do modelo *KNN* para $k = 3$.

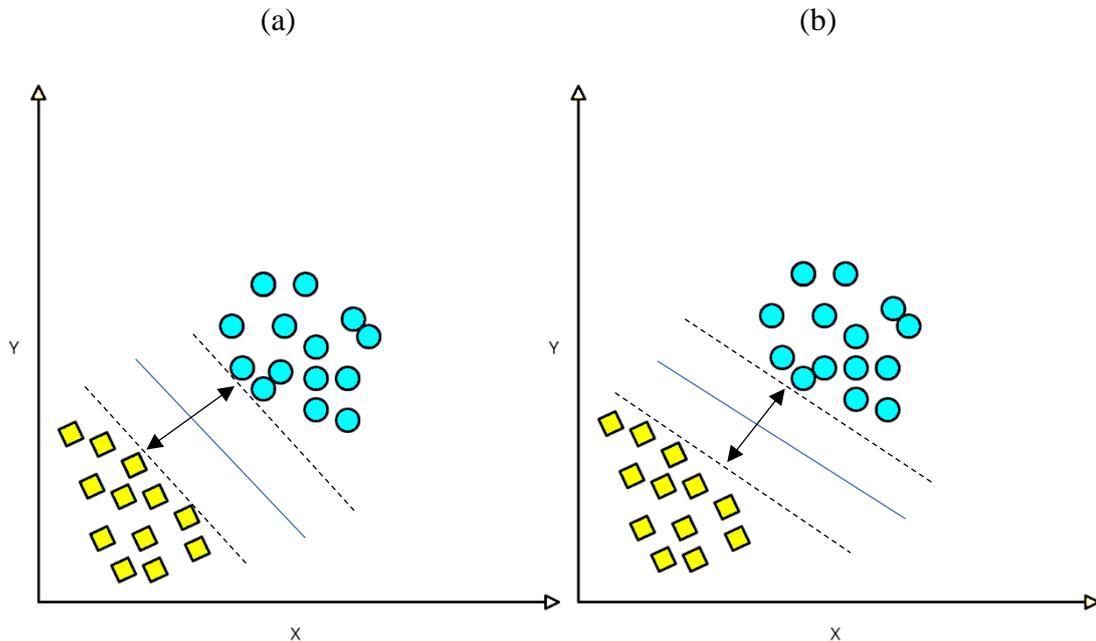


Fonte: O próprio autor (2024).

2.2.3 *Support Vector Machine*

Em linhas gerais, o modelo mais simples do *Support Vector Machine*, se propõe a encontrar um hiperplano que obtém a separação entre dados de treinamentos linearmente separados. Esse modelo é chamado de Classificador de Margem Máxima. Esse classificador consegue encontrar um plano de classificação ótima, que separa um conjunto de vetores sem erro, onde a distância entre vetores (das classes opostas) mais próximos ao hiperplano, conhecidos como vetores de suporte, é máxima (VAPNIK; 1988).

Figura 2.5 - Hiperplano com Margem Máxima (a) e Hiperplano com Margem Menor (b).



Fonte: O Próprio Autor (2024).

Ainda que esse classificador seja simples para problemas de classificação, sua implementação apenas é possível se existir um hiperplano que separe perfeitamente os dados de treinamento de acordo com a classe a que os mesmos pertencem. Entretanto, para a maioria dos problemas reais, não é possível definir esse hiperplano, pois algumas observações de diferentes categorias da variável resposta podem estar sobrepostas (JAMES; WISTEN e HASTIE, 2014).

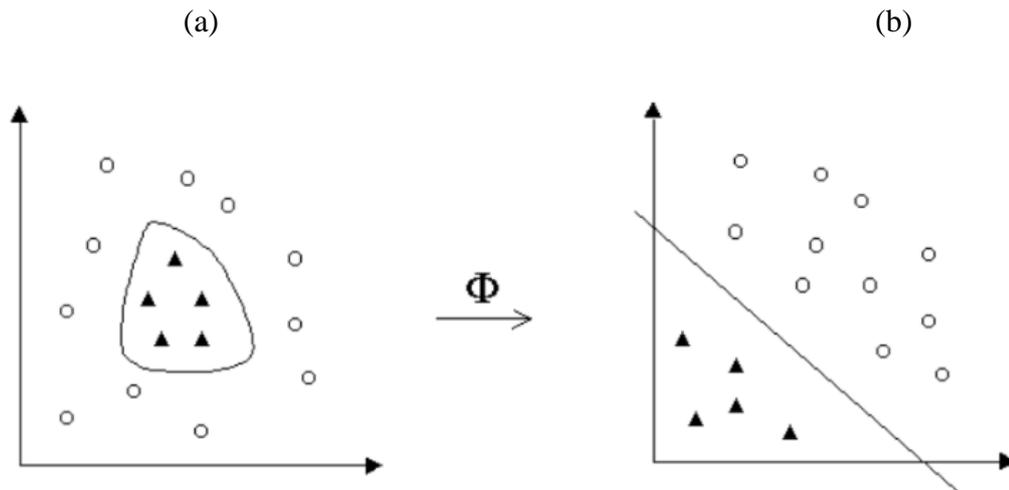
Nesse caso, para fronteiras de decisão lineares, é possível estender o conceito de hiperplano separador a fim de considerar hiperplano de margens suaves, também denominados hiperplanos de vetores de suporte, que ao separar as observações de classes distintas toleram que algumas estejam localizadas do lado incorreto da margem, ou mesmo, do hiperplano separador (JAMES; WISTEN e HASTIE, 2014).

De acordo com Carvalho (2012) outra forma usada pelo *SVM* para permitir a classificação de dados não linearmente separáveis, é com a aplicação do conceito de Kernel, cuja ideia é projetar dados a partir de um espaço de baixa dimensão para um plano de alta dimensão. A estratégia, neste caso, envolve mudar a representação dos dados da seguinte forma, como identificado na equação à seguir:

$$x = (x_1, \dots, x_n) \rightarrow \Phi(x) = (\Phi_1(x), \dots, \Phi_n(x))$$

Essa forma corresponde ao mapeamento do espaço de entrada X , em que os dados não são linearmente separáveis, em um novo espaço $Z\{\phi(x)|x \in X\}$, chamado espaço de características, de dimensão maior, onde os dados passam a ser linearmente separáveis, em que ϕ , são as funções de Kernel (Figura 2.6).

Figura 2.6: Transformação do conjunto de dados no espaço de entrada(a) para um novo espaço (b).



Fonte: Lorena e De Carvalho (2002).

Existem diversos tipos de Kernels comumente utilizados, como o Kernel Linear, o Kernel Polinomial e o Kernel de Função de Base Radial (RBF). Cada tipo de Kernel utiliza uma função específica para mapear os dados em um espaço de maior dimensionalidade. O Kernel RBF é bastante utilizado devido à sua flexibilidade e capacidade de lidar com problemas complexos.

2.2.4 Indicadores de Desempenho e Validação Cruzada Espacial

De acordo com James, *et. al.* (2013), a precisão é a razão entre o número de verdadeiros positivos (TP) e a soma dos verdadeiros positivos e falsos positivos (FP), ou seja, a proporção de instâncias classificadas corretamente como positivas em relação a todas as instâncias classificadas como positivas pelo modelo, conforme mostrado na equação abaixo:

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}}$$

A revocação (*recall*) é a razão entre o número de verdadeiros positivos (TP) e a soma dos verdadeiros positivos e falsos negativos (FN), ou seja, a proporção de instâncias positivas corretamente identificadas em relação a todas as instâncias positivas no conjunto de dados (SOKOLOVA; LAPALME, 2009), de acordo com a seguinte equação:

$$Revocação = \frac{Verdadeiros\ Positivos}{Verdadeiros\ Positivos + Falsos\ Negativos}$$

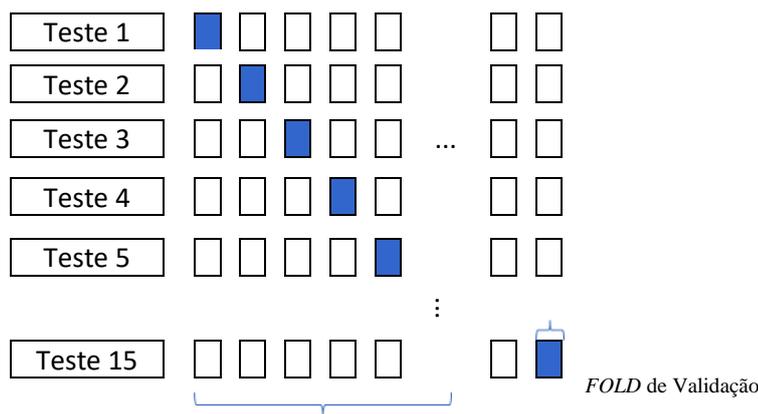
O *F1-score* é a média harmônica entre precisão e recall. Ele é definido como 2 vezes o produto da precisão e *recall*, dividido pela soma da precisão e recall. (SOKOLOVA; LAPALME, 2009). Tal relação é identificada na equação à seguir:

$$F1 = \frac{2 * Precisão * Revocação}{Precisão + Revocação}$$

Em conjuntos de dados desbalanceados, onde a classe minoritária muitas vezes é a mais interessante, o *F1 Score* é crucial, pois evita que a métrica seja dominada pelo desempenho na classe majoritária.

Para evitar problemas de *overfitting*, além da avaliação dos indicadores de desempenho, é necessário, em alguns casos, aplicar técnicas de Validação Cruzada para avaliar a capacidade de generalização de padrões. A Validação Cruzada consiste na subdivisão do conjunto de dados de treinamento em quadrantes (*K Folds*) e utilização de um dos quadrantes, por vez, para avaliação, como mostra a figura a seguir:

Figura 2.7: Validação Cruzada com 15 Folds.



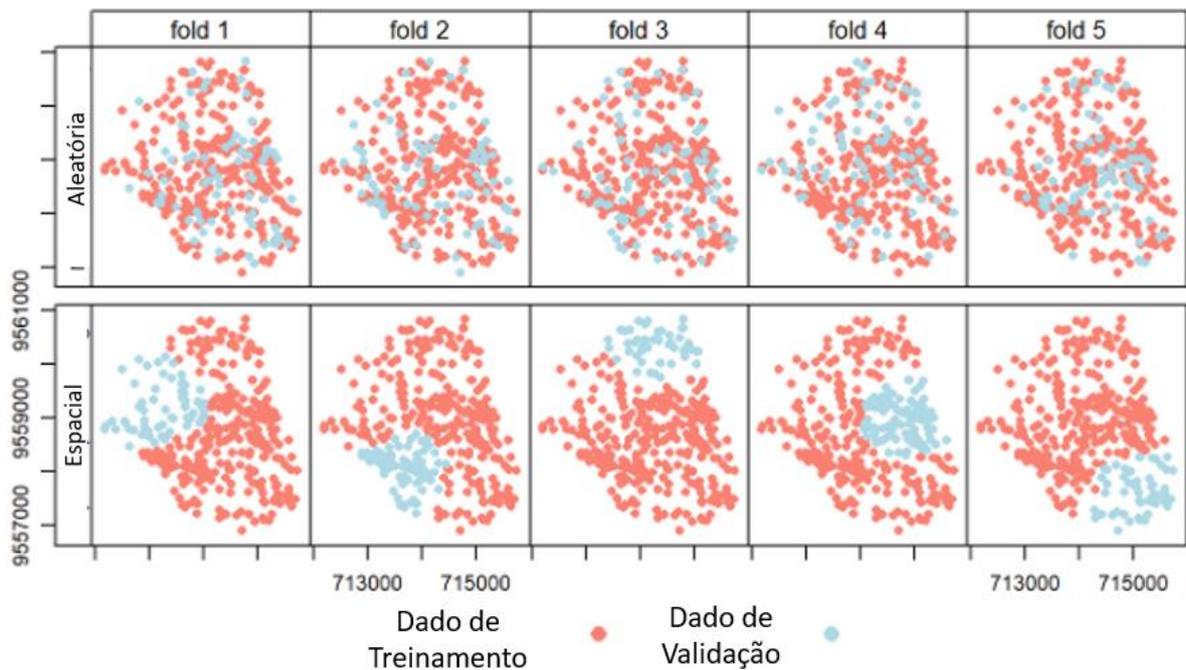
O Próprio Autor (2024).

Uma das limitações da validação cruzada padrão ocorrem quando essas seções são correlacionadas entre si, uma vez que se usarmos amostras aleatórias para divisão de dados de avaliação e de treinamento na validação cruzada, podemos estar ignorando o fato de que as amostras não são estatisticamente independentes (correlação espacial).

Como os dados de validação cruzada padrão são capturados de modo aleatório, dados de avaliação e treinamento, podem ter natureza espacial muito semelhante, o que faz com que naturalmente compartilhem recursos semelhantes. Isso, novamente colaboraria para a generalização de padrões e acertos ligados à validação que desconsidera os padrões existentes de espacialidade.

Para corrigir esse viés, utiliza-se como estratégia agrupar os dados de treinamento e teste por área, impedindo assim, que o modelo capture dados que são naturalmente semelhantes a outros quadrantes. A essa técnica chamamos de Validação Cruzada Espacial (Figura 2.8).

Figura 2.8: Diferença entre o particionamento de validação cruzada convencional e espacial.



Fonte: Adaptado de Lovelace, Nowosad e Muenchow, 2021.

3. ESTUDO DE CASO

Este capítulo apresenta um estudo de caso realizado no município de Parauapebas, sudeste do Pará, na cava 2 do corpo N4E, situado no Platô Norte da Serra dos Carajás, dentro do agrupamento Serra Norte, um depósito ferrífero de relevante interesse geológico e econômico. A investigação centrou-se na aplicação de Veículos Aéreos Não Tripulados (VANTs) equipados com a tecnologia de câmera S.O.D.A de alta resolução e sensor RTK/PPK, permitindo a captura de imagens georreferenciadas com precisão notável, fundamentais para a análise litológica avançada da região.

A aquisição de dados foi realizada pelo VANT *Sensefly*, resultando em uma nuvem de pontos densa, processada e analisada por meio do software *Cloud Compare* e da linguagem de programação *Python*, utilizando bibliotecas como *Pandas*, *Numpy* e *SciKit-learn*. Este enfoque metodológico proporcionou um tratamento e análise de dados rigorosos, empregando Classificação Supervisionada e técnicas de processamento avançado para interpretar e organizar as informações coletadas.

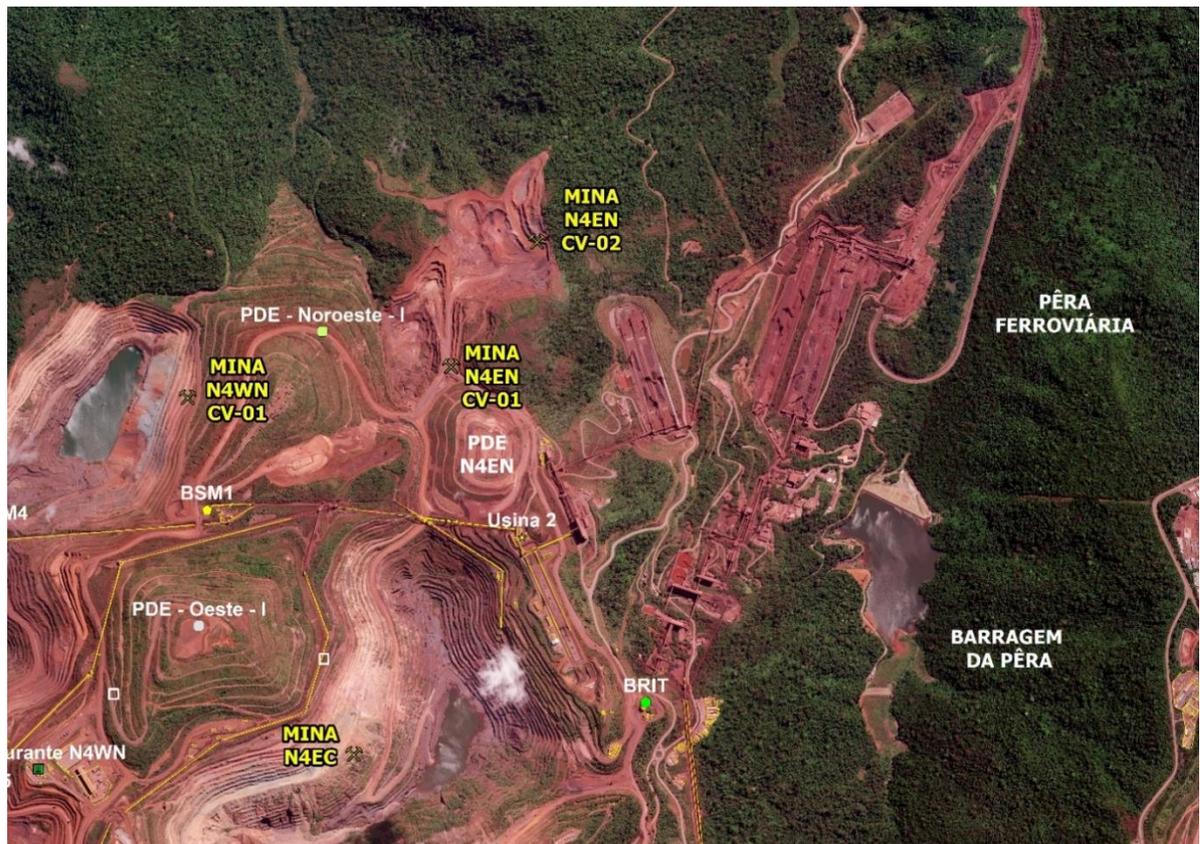
A fase de aquisição de dados gerou uma rica base para a criação de uma nuvem de pontos tridimensional, refletindo com precisão a topografia e a complexidade litológica da área estudada. A subsequente etapa de classificação manual, apoiada por validações em campo, permitiu a identificação precisa de diferentes litotipos, essencial para o entendimento geológico do local.

Este estudo exemplifica o poder da integração de tecnologias avançadas, como VANTs e análise computacional, na geociência, destacando a importância de coletas de dados em alta resolução para o mapeamento e análise detalhada de frentes de lavra. Através da combinação de técnicas modernas de sensoriamento remoto, processamento de imagens e aprendizado de máquina, foi possível alcançar uma compreensão mais profunda e detalhada da área de interesse, estabelecendo um marco no estudo e exploração de recursos minerais.

3.1 ÁREA DE ESTUDO

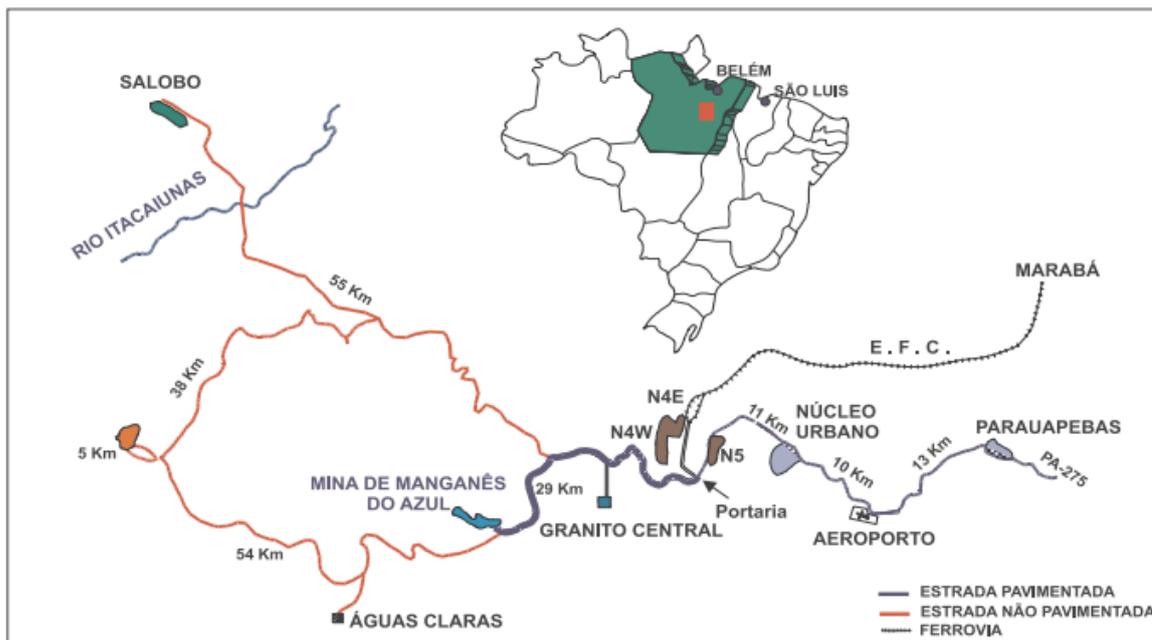
A área estudada localiza-se no município de Parauapebas, no sudeste do Pará, no Platô Norte da Serra dos Carajás, no agrupamento denominado Serra Norte, mais especificamente no corpo N4E, especificamente na cava 2, presente no depósito ferrífero de N4 (Figura 3.1).

Figura 3.1: Imagem Aérea da Mina de N4E – Cava 2.



Fonte: VALE, 2021.

Figura 3.2: Mapa Província Mineral de Carajás.

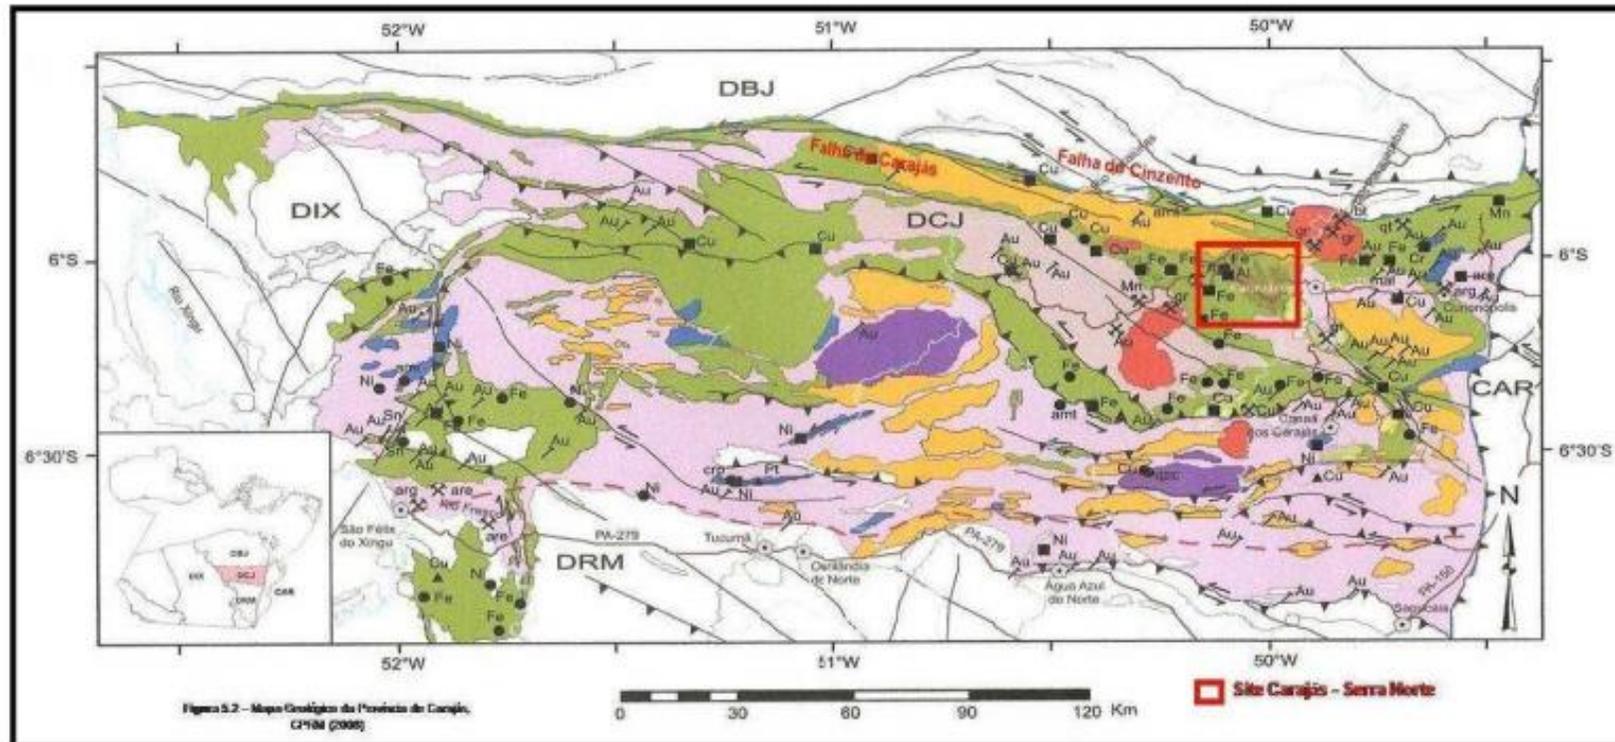


Fonte: COSTA; FERNANDEZ e REQUELME, 2005.

A geologia da Província Mineral de Carajás (Figura 3.2) é complexa e remonta a milhões de anos atrás, com a formação de rochas ígneas, metamórficas e sedimentares. Um dos aspectos mais marcantes é a presença do Complexo Vulcânico de Carajás, composto por rochas metavulcânicas formadas há mais de 2,7 bilhões de anos. Essas rochas são ricas em minerais de ferro, como a hematita e a magnetita, que são exploradas em larga escala na região. (Monteiro *et al.*, 2008).

A província mineral de Carajás está inserida no Domínio Carajás, na porção leste do Escudo Brasil Central, sendo limitada a leste pelos rios Araguaia-Tocantins, a oeste pelo rio Xingú, a norte pela Serra do Bacajá e a Sul pela Serra dos Gradaús (DOCEGEO, 1988).

Figura 3.3: Mapa Geológico – Província Mineral de Carajás.



Associações Tectônicas do Domínio Carajás		Terreno Granitóide-Greenstone Neocarqueano	
Magmatismo Físico Intracontinental		A4y	Granitos de Alto K Neocarqueanos - granitos potássicos neocarqueanos (2763-2730 Ma). Complexo Granítico Estrela, granitos Plaqué, Planalto, Serra do Rabo e Igarapé Gelado.
PP34ya	Suites Plutônicas Alcalinas Intracontinentais - granitos de afinidade alcalina relacionados à extensão crustal orosiriana/esteleriana. Suite Intrusiva Serra dos Carajás (1883-1874 Ma).	A4z	Complexo Máfico-Ultramáfico Neocarqueano - corpos máfico-ultramáficos neocarqueanos. Complexo Máfico-Ultramáfico Luanga (2763 Ma).
Magmatismo Máfico-Ultramáfico Intracontinental		A4yb	Greenstone Belts Neocarqueanos - seqüências metavulcano-neocarqueanas (2775-2740 Ma). Grupos Rio Novo, São Félix, São Sebastião, Açú, Grlho Parã, Igarapé Bahia, Igarapé Pojuca e Igarapé Salobo.
PP1z	Complexo Máfico-Ultramáfico Sideriano - corpos máfico-ultramáficos siderianos. Suite Intrusiva Cateté (2378 Ma).	Embasamento Mesoarqueano	
Bacia Sedimentar Arqueana		A3gn	Associação granito-gnássico-migmatítica Mesoarqueana - ortognaisses migmatíticas com pródoto (2974 Ma) e metamorfismo de alto grau (2889 Ma) mesoarqueanos. Complexo Xingu.
A4bcp	Bacia Cratônica Plataforma Neocarqueana - seqüência plattformar regressiva de sedimentação neocarqueana. Formação Águas Claras (< 2778 e > 2708 Ma).	A3gl	Associação Granulítica Mesoarqueana - ortogranulitos com pródoto (3002 Ma) e metamorfismo granulítico (2959 Ma) mesoarqueanos, com chernockitos máficos contemporâneos. Ortogranulito Chirim-Cateté e Diopsído Norte Plum.

Fonte: CPRM, 2008.

Santos (2003), dividiu a Província dos Carajás nos Domínios Carajás e Rio Maria. A parte norte da Província Mineral de Carajás é onde está presente o Domínio Carajás e abrange a Serra de Carajás e sua região, que inclui os depósitos de ferro da Serra Norte (N1 a N9), sul (S1 a S45) e leste; os depósitos da classe óxidos de Fe, Cu-Au, Salobo, Pojuca, Alemão, Igarapé-Bahia, Cristalino, Sossego, Alvo118, Gameleira, Manganês Azul, e do Níquel Vermelho. Este domínio é restringido na sua porção norte por rochas graníticas sintectônicas do Cinturão Maroni-Itacaiúnas (Macambira et al. 2003).

Em Serra Norte, mais especificamente na Mina de N4E, área de estudo desse trabalho, os depósitos de Ferro são caracterizados pelos seguintes litotipos (VALE, 2021):

- a) Jaspilito: O jaspilito é, no geral, esbranquiçado, e representa o protólito dos depósitos de ferro de Carajás. Ocorre predominantemente na base das formações ferríferas, em contato com rochas máficas ou sob a forma de lentes, imersas em uma grande massa de hematita friável. A espessura das lentes costuma ser pequena (poucos metros), variando de centímetros a cerca de 20 m. O jaspilito que ocorre na porção basal pode atingir até 350 m de espessura, sendo desconhecida a continuidade em profundidade em algumas regiões da mina. Na grande massa de jaspilito, que constitui a base da formação ferrífera, as lentes de hematita, são observadas em regiões próximas ao contato topo jaspilito/hematita.
- b) Hematita: é o tipo predominante de minério, ocorre ao longo de todas as minas. Possui coloração variando do preto a cinza avermelhado, sendo esta última típica de cimentação por goethita/limonita, cimentação esta entendida como responsável pela elevada compacidade deste litotipo. Possui espessura variável no perfil de enriquecimento, atingindo até 350 m e grande continuidade ao longo do mergulho.
- c) Máficas: As máficas representam um produto do intemperismo nas sequências de rocha típicas da região. Apresenta elevado grau de alteração, pouco estruturada, com coloração variando de alaranjada a amarelada, argilosa, chegando à estruturas esverdeadas, com consistência predominantemente macia.

3.2 METODOLOGIA

A metodologia deste estudo é estruturada para obter e processar dados geoespaciais, visando gerar um mapa final de classificação supervisionada. Ela se inicia pela etapa de aquisição de dados, onde são mostradas informações sobre as ferramentas utilizadas para obtenção de dados, os tipos de dados utilizados e a frente de lavra processada, assim como a nuvem de pontos gerada. Em seguida é debatido sobre o processamento de dados, em que se disserta sobre o tratamento inicial da nuvem de pontos (classificações) e metodologia usada para a vetorização dos pontos amostrados. Por fim, são identificadas as ferramentas usadas para a geração e avaliação do modelo de classificação.

3.2.1 Aquisição de Dados

Nessa fase, que compreendeu a geração da base de dados e criação da nuvem de pontos, foi gerada uma nuvem de pontos por meio da sobreposição de duas ou mais imagens que formam um conjunto de pontos, no espaço tridimensional. A Figura 3.4: Fotografia na frente de Lavra em Estudo. mostra a frente de lavra usada nesse estudo, gerada por uma câmera fotográfica comum.

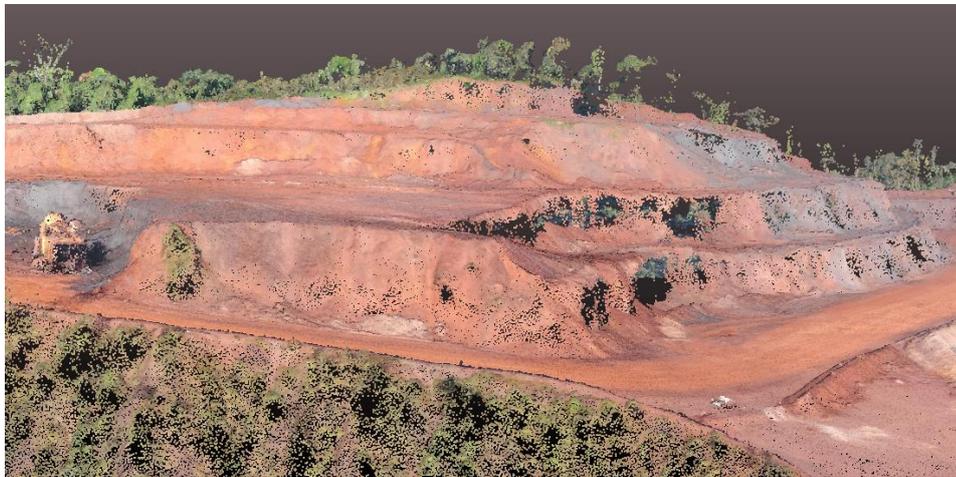
Figura 3.4: Fotografia na frente de Lavra em Estudo.



Fonte: O Próprio Autor (2024).

A 3.5 ilustra a nuvem de pontos “densa”, composta por um total de 2.724.876 pontos, na frente de lavra usada para desenvolvimento desse trabalho. A captura de Imagens ocorreu através do VANT *Sensefly*, operando com uma câmera de resolução de 2,9 cm/ pixel e sensor do tipo S.O.D.A. Tal equipamento, conta com a função RTK/PPK, que permite que as imagens capturadas já venham georreferenciadas com alta acurácia em tempo real que permite alcançar precisão de até 2,5 cm. O drone capturou as imagens no dia 05 de Novembro de 2021, no período da manhã, obtendo um total de 567 imagens, que foram combinadas.

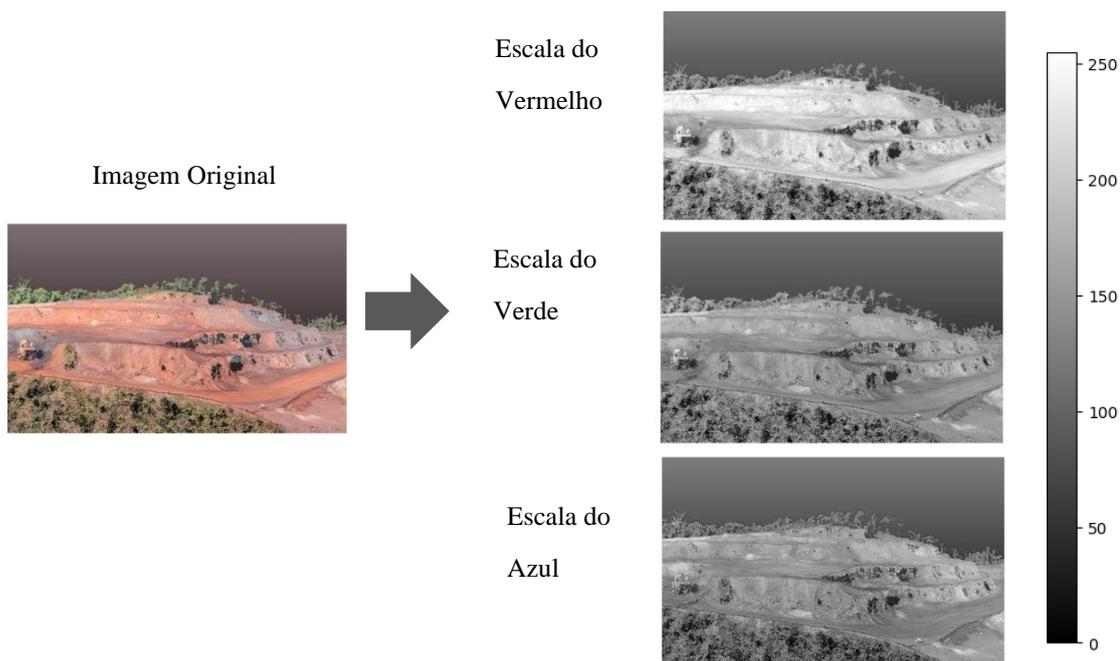
Figura 3.5: Nuvem de pontos densa da frente de lavra, gerada a partir de imagens de Drone.



Fonte: O Próprio Autor (2024).

Na nuvem de pontos gerada, além das informações de altura, coordenadas X e Y, foram obtidas informações de componentes de cores vermelho, verde e azul (*RGB*, do inglês, *Red*, *Green* e *Blue*), que foram tratadas na etapa de processamento de dados. Os valores numéricos de R, G e B, variam entre valores de 0 e 255, como mostrado na Figura 3.6.

Figura 3.6: Escala R, G e B.



Fonte: O Próprio Autor (2024).

3.2.2 Processamento de Dados

A etapa de processamento de dados foi dividida em duas etapas: a classificação manual e a criação de vetores.

3.2.2.1 Classificação Manual

Essa etapa consistiu em classificar a nuvem de pontos (Figura 3.7) de acordo com a cor característica do respectivo litotipo. As informações de cor foram integradas como características de entrada para orientar a seleção dos litotipos. Além disso, a realização de validações em campo foi essencial para minimizar interferências como sombras e variações de iluminação.

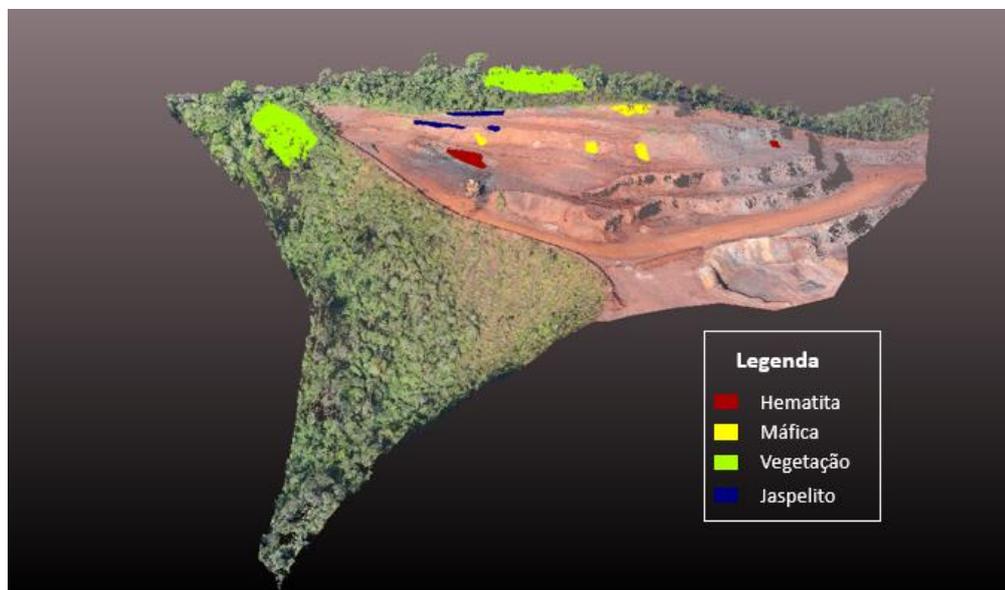
A classificação e manuseio das nuvens de pontos foi desenvolvida através do software *Cloud Compare* que fornece um conjunto de ferramentas básicas para editar e renderizar manualmente nuvens de pontos 3D e malhas triangulares.

Foram selecionadas regiões de 4 litotipos distintos, através do *software cloud compare*: vegetação, hematita, máfica e jaspilito. O procedimento envolveu o recorte de algumas seções da nuvem de pontos e a criação de etiquetas com as referências à tais regiões. O *software Cloud Compare* foi usado para essa operação e permitiu seccionar conjuntos de pontos através de uma ferramenta de tesoura e estabelecer atributos nominais à base de dados gerada, nesse caso, de litotipo.

Foram realizadas duas classificações: na primeira selecionou-se regiões preferencialmente pertencentes à um grupo exclusivo de litotipo (Figura 3.7) e na segunda classificação optou-se pela seleção de regiões adjacentes, pertencentes à limites ou a mais de um grupo litológico (Figura 3.8).

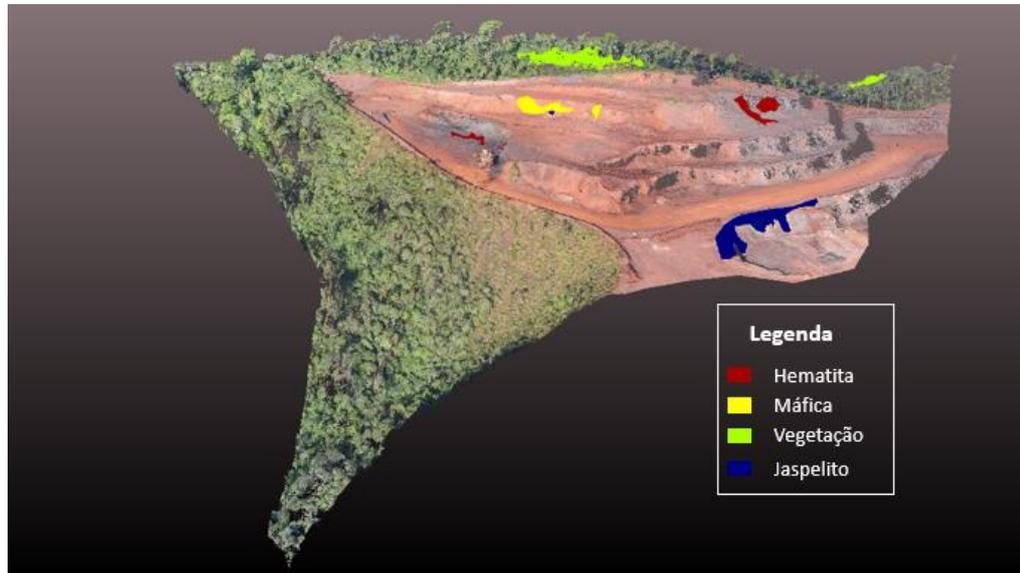
A primeira classificação teve um percentual de 5,4% do número total de pontos classificados e a segunda um percentual de 4,2% do número total de pontos classificados, de acordo com a quantidade de pontos informadas nas tabelas 3-1 e 3-2, respectivamente referidas ao grupo homogêneo e de regiões adjacentes.

Figura 3.7: Classificação Litológica em grupos pertencentes a classes litológicas bem definidas.



Fonte: O Próprio Autor (2024).

Figura 3.8: Classes litológicas pertencentes a zonas de contatos ou zonas de interseção entre mais de um litotipo.



Fonte: O Próprio Autor (2024).

Respeitando algumas limitações provocadas pela heterogeneidade presente na frente de lavra, as amostragens consideraram uma quantidade classificada que garantiu a representatividade dos litotipos em estudo (Tabela 3-1).

Tabela 3-1: Litotipos – Zona de maior homogeneidade amostral.

Classe	Número de Pontos	% em relação ao Grupo
Máfica	6750	0,25%
Hematita	8965	0,33%
Jaspilito	23118	0,85%
Vegetação	75620	2,78%
Remanescente	2610423	95,80%
Total	2724876	100,00%

Fonte: O Próprio autor, 2024.

Tabela 3-2: Litotipos – Zona de maior heterogeneidade amostral.

Classe	Número de Pontos	% em relação ao Grupo
Máfica	4399	0,16%
Hematita	7517	0,28%
Jaspilito	12391	0,45%
Vegetação	121774	4,47%
Remanescente	2578795	94,64%
Total	2724876	100,00%

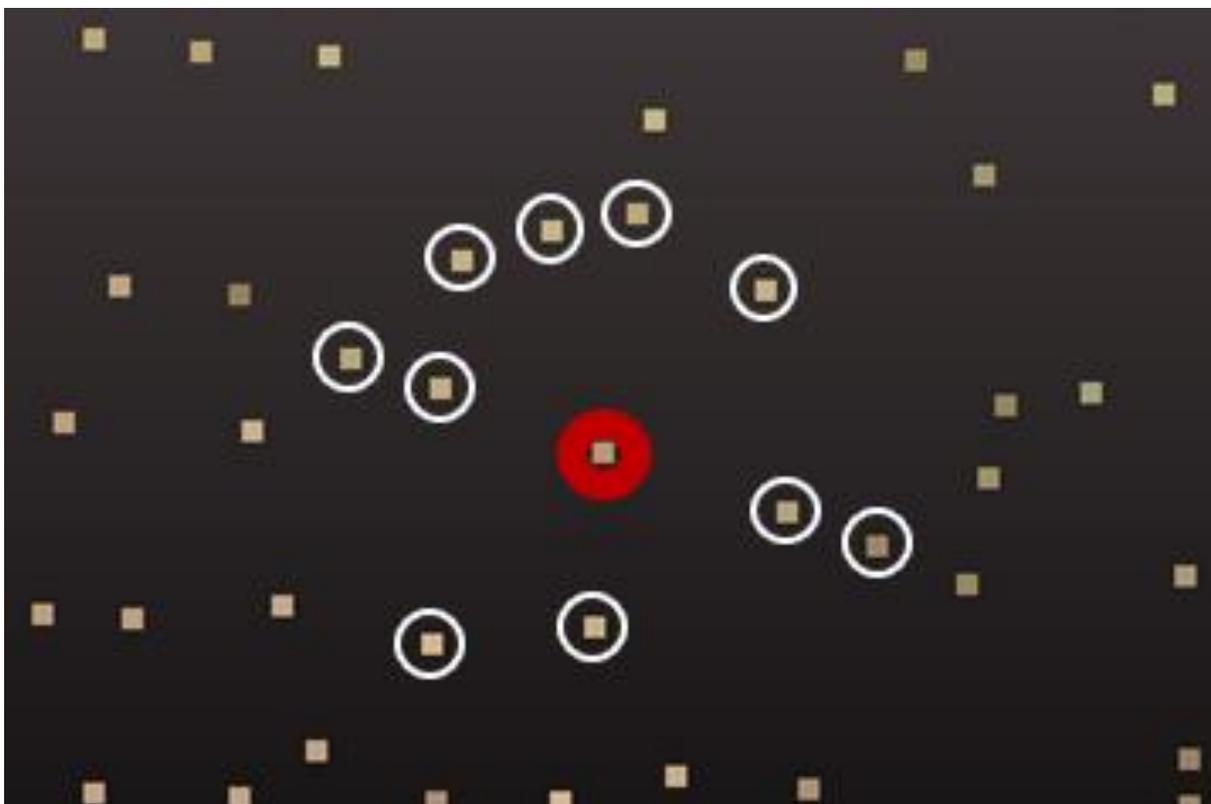
Fonte: O Próprio autor, 2024.

3.2.2.2 Criação de Vetores

Cada ponto na nuvem representa um conjunto de atributos específicos daquele ponto, individualmente. Levando em consideração o fenômeno de correlação espacial na área amostrada e a presença de espaços sem informação entre os pontos de atributos, foi necessário realizar um processamento de dados para que cada ponto de dados seja associado a um vetor de características, que representasse esse conjunto de pontos de dados. Para a criação de vetores, foram realizados os seguintes passos:

1. Foi realizada uma amostragem aleatória de um percentual específico dos dados categorizados, de modo a formar centroides, que irão criar o conjunto de dados que será utilizado para formar os vetores. Os percentuais testados para a amostragem desses centros foram de 50%, 35% e 20% de pontos selecionados para formar centros. Cada ponto amostrado recebeu um ID único, que permite fazer referência a ele de forma individual;
2. Uma busca por n pontos mais próximos foi realizada, de acordo com a localização espacial, e separaram-se os resultados de R, G e B dos pontos selecionados;

Figura 3.9: Esquema mostrando o raio de busca de um centroide.

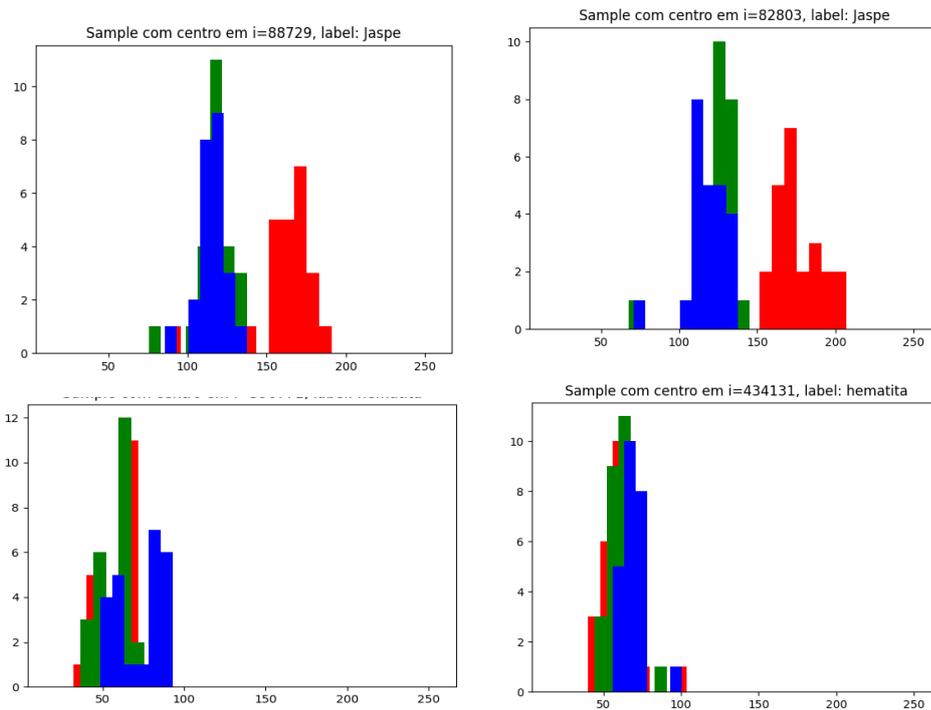


Fonte: O Próprio Autor (2024).

Na figura 3.9 é mostrado o ponto (em Vermelho), que representa um dos centros amostrados, com ID definido, e dez pontos mais próximos ($n = 10$) do centro selecionado. O vetor possibilitará registrar as informações dos pontos da extremidade, o que minimiza a interferência dos espaços vazios. O grande desafio da escolha de um valor para n é determiná-lo de modo que não ocorra uma “perda” de informações por conta da exclusão de pontos considerados e ao mesmo tempo não ocorra uma sobreposição de informações pela escolha de um valor de n elevado.

3. As plotagens de histogramas, para cada uma das classes, permitiram identificar padrões R, G e B distintos para as classificações analisadas, o que auxiliou na determinação dos canais dos histogramas que formaram os vetores. Foram identificados padrões, para pontos diversos, de uma mesma classe. Na figura abaixo é possível visualizar o padrão de distribuição para R, G e B para hematita e jaspilito que concentram valores da escala R, G e B, respectivamente à direita ao centro.

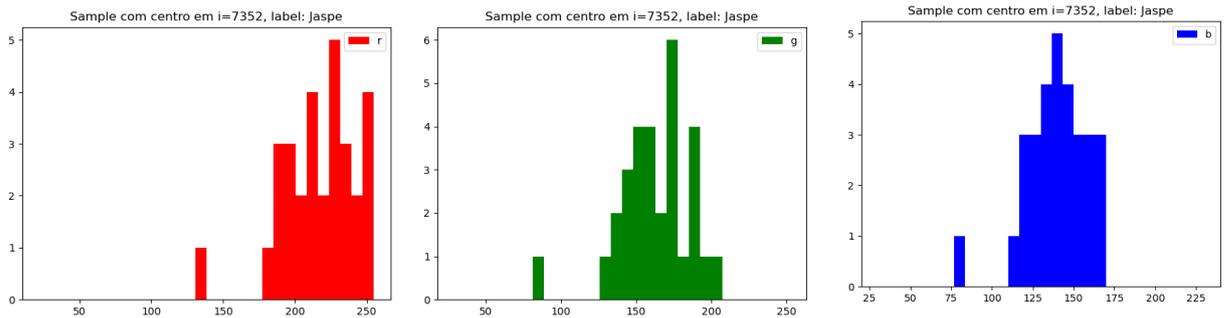
Figura 3.10: Histogramas de classes Hematita e Jaspilito e canais R, G e B.



O Próprio Autor (2024).

- Foram gerados histogramas (Figura 3.11) a partir das frequências das informações R, G e B para o conjunto de n pontos capturados. Esses histogramas foram divididos em 30 canais, com intervalos de 8,5 pontos entre eles, formando os limites numéricos de RGB, que variam entre 0 a 255. Isso permitiu analisar a distribuição dos dados de forma mais detalhada.

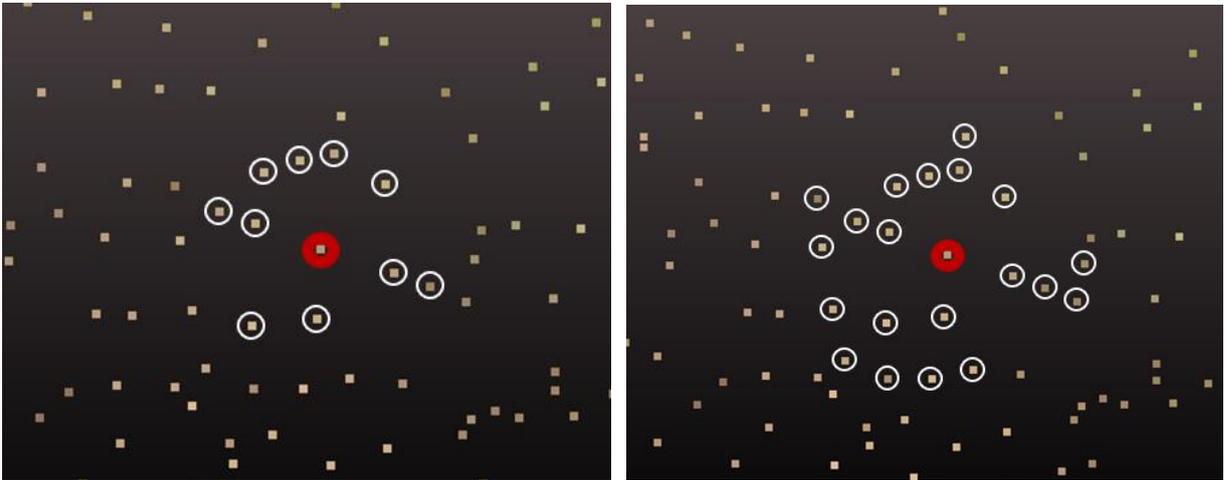
Figura 3.11: Histogramas com frequências R, G e B.



O Próprio Autor (2024).

- O mesmo procedimento foi realizado, variando o número n de vizinhos de 10 em 10, de 10 a 90 vizinhos considerados.

Figura 3.12: Centroide “capturando” respectivamente os dados de 10 e 20 vizinhos mais próximos a ele.



Fonte: O Próprio Autor (2024).

- Para cada histograma, gerou-se um vetor com as informações do conjunto de dados avaliados.

3.2.3 Geração e Avaliação do Modelo

Quatro modelos de classificação foram testados, para cada variação de raio de busca, através da utilização da biblioteca de *Python ScikitLearn*. Foram utilizados os algoritmos *Support Vector Machine Linear e Radial (SVM – L e SVM – R)*, *Random Forest (RF)* e *Gradient Tree Boosting (GTB)* para a comparação de desempenho. Todos os hiperparâmetros foram aplicados como originais da biblioteca e o número de árvores de decisões usados para o *RF* e *GTB* foi de 100.

Todo o tratamento e análise de dados foram feitos utilizando a linguagem de programação *Python*. Para o carregamento e processamento dos dados foram utilizadas as bibliotecas *Pandas* e *Numpy* e para os modelos de classificação foi usada a biblioteca *SciKit-learn*.

Duas medidas de desempenho foram avaliadas para a comparação dos algoritmos: Precisão, *Recall* (Revocação) e F1 uma vez que eles são mais indicados para projetos com dados de grupos desbalanceados, o que é o caso do presente trabalho.

Para evitar problemas de *overfitting*, além da avaliação dos indicadores de desempenho, foi necessária a aplicação de técnicas de Validação Cruzada para avaliar a capacidade de generalização de padrões.

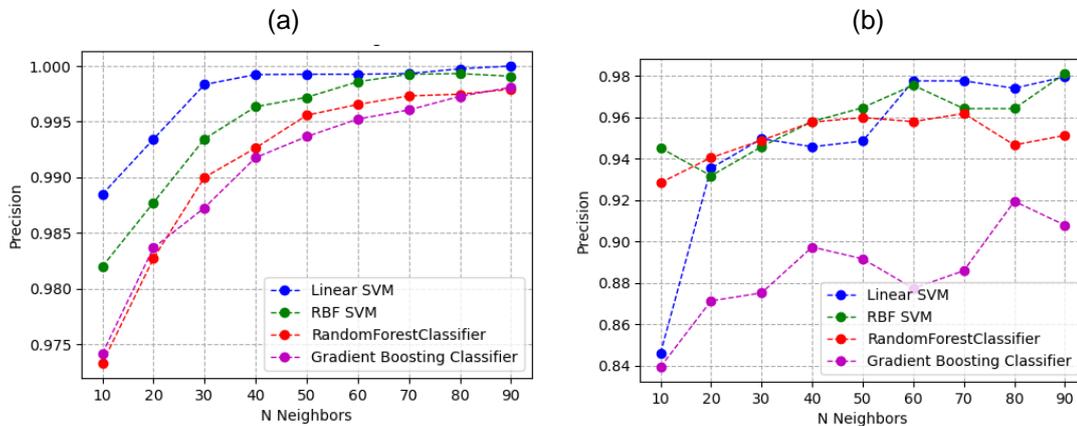
3.3 RESULTADOS E DISCUSSÃO

Nas Figuras 3.13 a e b são apresentados os resultados de precisão obtidos a partir de uma amostra que corresponde a 50% dos pontos utilizados como centros nos quatro algoritmos testados, utilizando os dados de teste. Esses resultados referem-se a dois cenários distintos: a amostragem em regiões preferenciais de homogeneidade (a) e a amostragem em regiões de contato entre múltiplas zonas litológicas (b).

Observa-se que a precisão melhora à medida que o número N de vizinhos no raio de busca é aumentado. No entanto, é importante ressaltar que uma amostra com um raio de busca menor pode indicar a insuficiência de dados ao redor do ponto central, enquanto um número crescente de vizinhos pode resultar na inclusão de dados pouco relacionados ao ponto central, comprometendo, assim, a representatividade dos resultados. Além disso, uma possível consequência do aumento do tamanho do raio é a sobreposição de amostras, o que pode levar à obtenção de dados excessivamente semelhantes entre si.

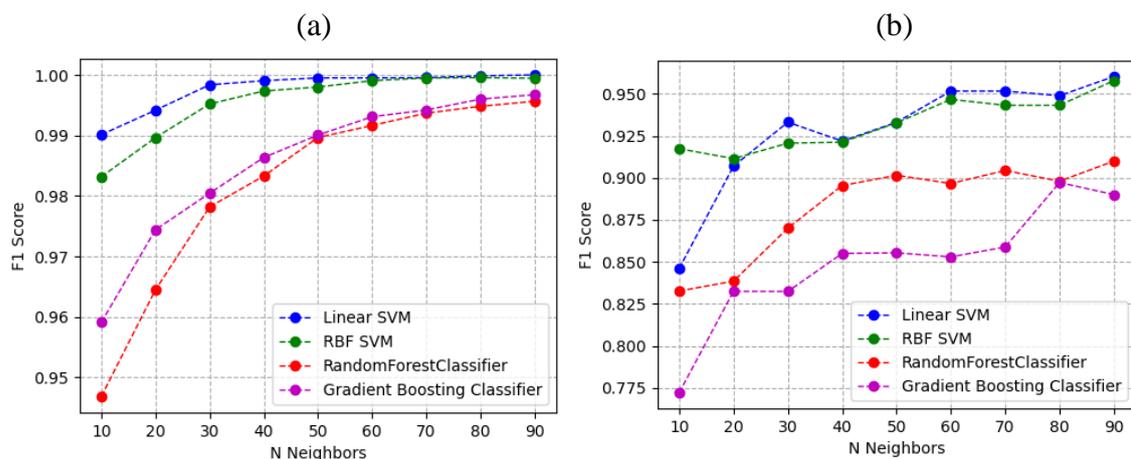
Durante a análise dos resultados de precisão, foi observada a presença de dois padrões de desempenho que permitem a divisão dos algoritmos em dois grupos distintos: o grupo *SVM* e o grupo *Random Forest* e *Gradient Boosting*. O grupo *SVM* alcança a máxima precisão nas zonas preferenciais de homogeneidade quando o raio de busca é de 60 vizinhos, enquanto o grupo *Random Forest* e *Gradient Boosting* não alcança um limiar de precisão comum aos grupos, demonstrando comportamento crescente ainda no raio de 90 (3.13 a). No caso da amostragem nas zonas de contato não é percebido atingimento de zona de limiar de precisão (3.13 b).

Figura 3.13: Precisão por número de vizinhos para áreas preferenciais (a) e zonas de contato (b).



Fonte: O Próprio Autor (2024).

Figura 3.14: F1 por número de vizinhos para áreas preferenciais (a) e zonas de contato (b).



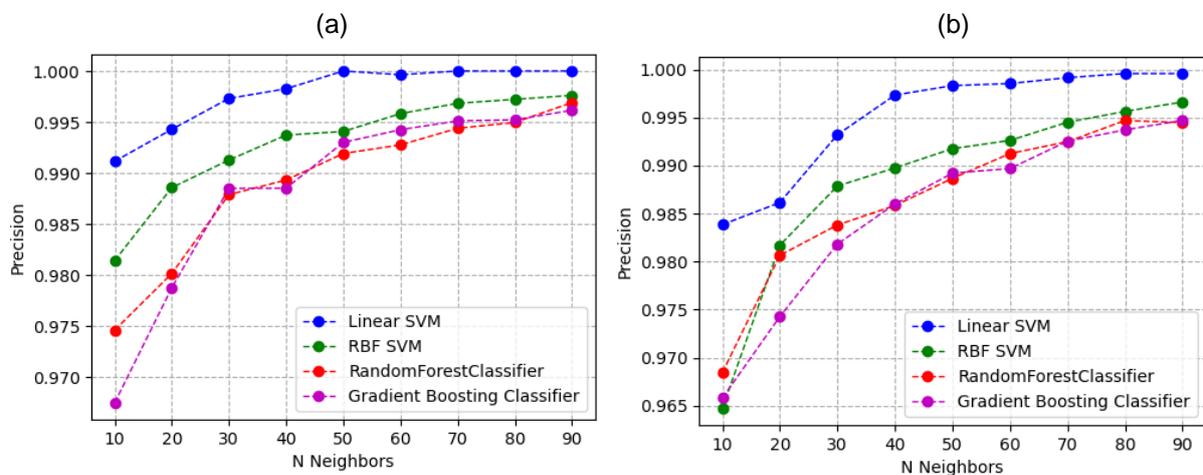
Fonte: O Próprio Autor (2024).

Assim como os resultados de precisão, os resultados da medida de *F1-Score* (Figura 3.14 a e b), utilizando dados de teste, também demonstraram indicadores superiores nas zonas de maior homogeneidade amostral em comparação com a amostragem nas zonas de contato e transição. Também foi possível a visualização de dois grupos de algoritmos, um formado pelos métodos de suporte (resultados superiores) e outro formado pelos métodos de *Random Forest* e *Gradient Boosting*. No geral, algoritmos de *SVM* são mais adequados à dados linearmente ou que possam ser linearmente separados, o que pode ser o caso.

Para as zonas de homogeneidade, entretanto, se tratando de *F1-Score*, foi possível identificar a saturação desse indicador nos algoritmos *Linear* e *RBF SVM* já no raio de busca 50. No entanto, para os algoritmos *Random Forest* e *Gradient Boosting*, não foi possível identificar uma zona de saturação até o raio de busca 90. O mesmo padrão ocorreu na amostragem das zonas de contato, com a zona de saturação não encontrada para nenhum dos algoritmos avaliados.

Uma vez que utilizando 50% dos dados de treinamento deve representar um aumento na intensidade nas zonas de influência regionais, foi necessário avaliar os mesmos indicadores em cenários com percentuais menores de amostras para os centros de busca. Assim, os resultados foram avaliados com amostragens de 35% e 20% dos centros. (Figuras 3.15 a e b) Os experimentos com 35% e 20% de amostras dos centros foram realizados utilizando os dados obtidos nas zonas de maior homogeneidade e seus resultados consideram dados de teste.

Figura 3.15: Precisão por Número de Vizinhos para respectivamente sub amostragem de 35% (a) e 20% (b).



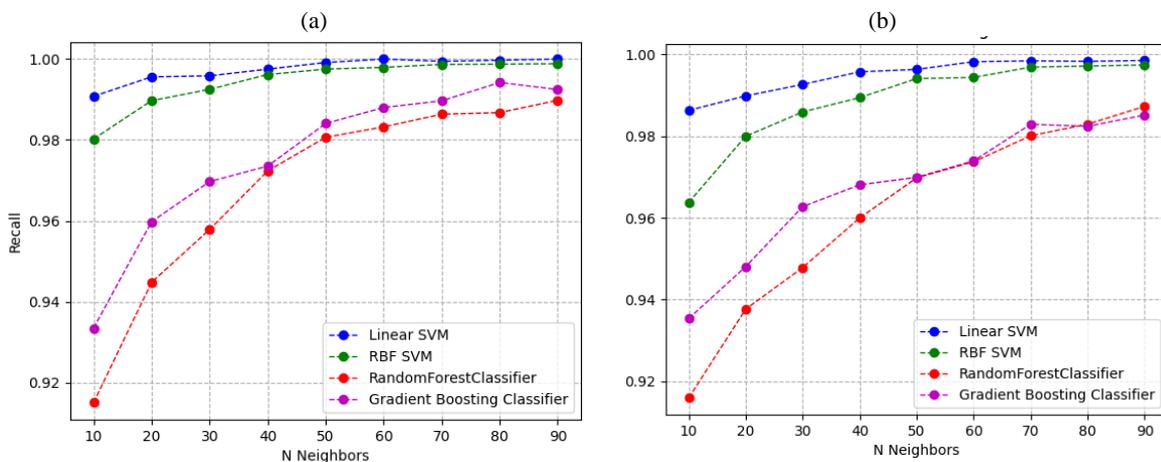
Fonte: O Próprio Autor (2024).

Para todos os algoritmos avaliados constatou-se desacoplamento maior da precisão máxima (1,0), à medida em que se diminuía o percentual de sub amostragem e o número de vizinhos, o que certamente é provocado pela superposição de áreas e aumento da influência de áreas sobre outras. Para 35% e 20% de sub amostragem inicial, constatou-se o ponto de equilíbrio para o algoritmo SVM Linear nos números de vizinho 50 e 70 respectivamente. Não se percebeu um atingimento dos pontos de equilíbrio para os algoritmos *Random Forest*, *Gradient Boosting* e *SVM Radial*.

Para os algoritmos *Random Forest* e *Gradient Boosting*, considerando a menor precisão, em relação aos demais algoritmos, verificou-se através de matrizes de confusão, como estariam as previsões, em erros e acertos, e para quais classes existe uma tendência maior de erros. Para ambos os casos, foram considerados 20% de amostragem dos centros e 30 vizinhos mais próximos, respectivamente.

Resultados para o indicador revocação, 35% e 20% de sub amostragem inicial, demonstraram um ponto de equilíbrio para o algoritmo SVM Linear e radial nos números de vizinho 50 e 70 respectivamente (Figura 3.16 a e b), o que demonstrou maior similaridade de resultados para os métodos de suporte e desempenho superior ao apresentado pelos métodos de árvore. Não se percebeu um atingimento dos pontos de equilíbrio para os algoritmos *Random Forest*, *Gradient Boosting* e foram aplicados na avaliação dados de teste.

Figura 3.16: Precisão por Número de Vizinhos para respectivamente sub amostragem de 35% (a) e 20% (b).

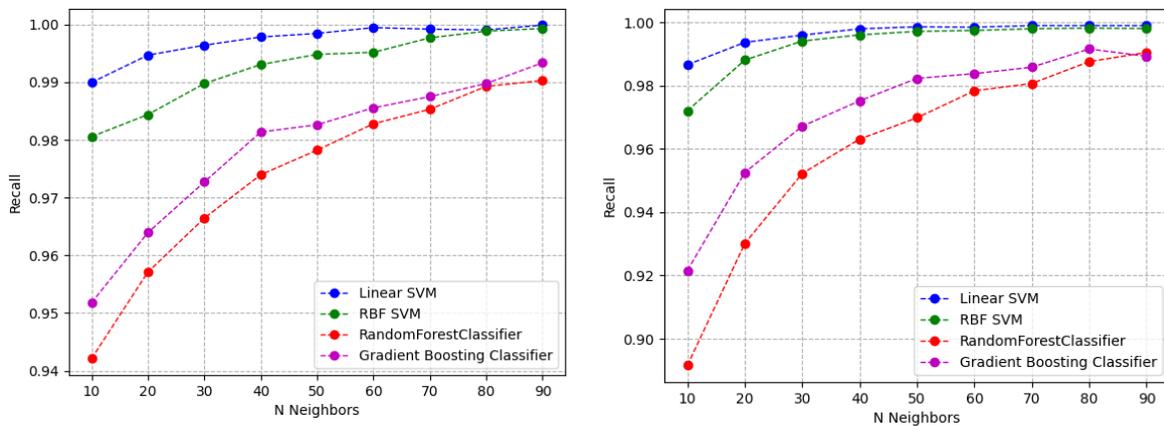


Fonte: O Próprio Autor (2024).

Para a avaliação da influência do número de canais dos histogramas criados no processo de vetorização no desempenho dos algoritmos, foram verificados, além dos vetores gerados com 30 canais (usados em todos os dados gerados nas avaliações anteriores), resultados de revocação com 15 e 45 canais (Figuras 3.17 a e b, respectivamente), ambos considerando 35% de amostras de centros e dados de teste.

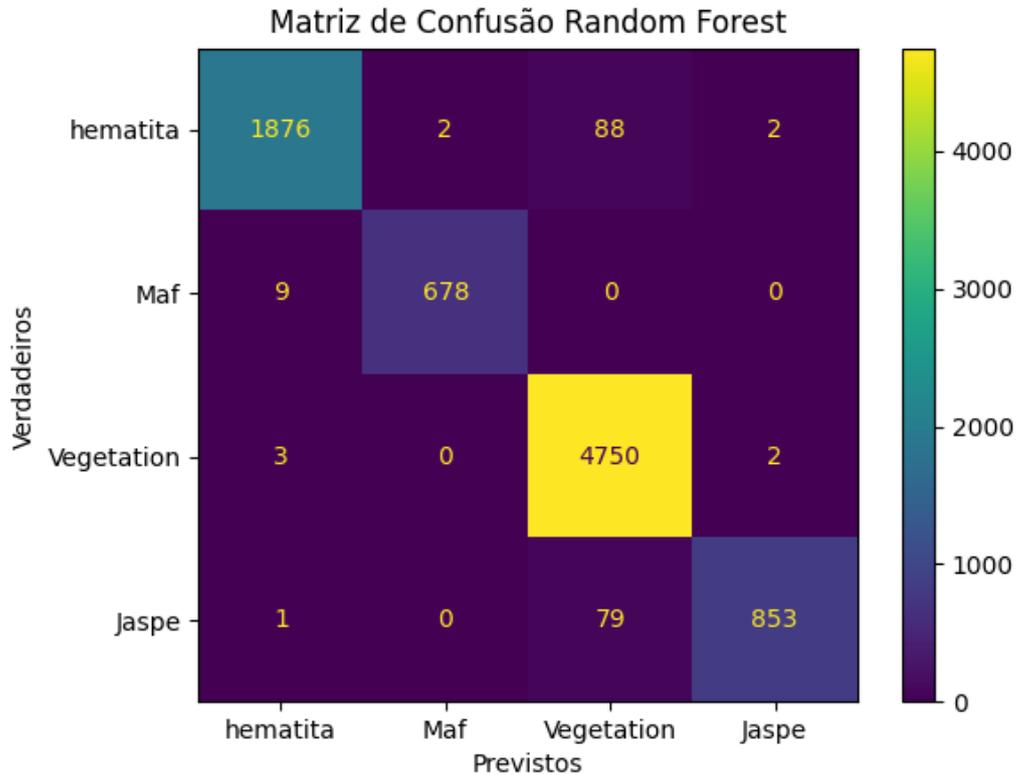
Não foi identificada clara correlação entre o número de canais e desempenho para algoritmos de suporte. Para algoritmo de árvores percebeu-se que o indicador de revocação foi maior, nos pontos identificados, quanto menor foi o número de canais.

Figura 3.17: Revocação por Número de Vizinhos para 15 (a) e 45 canais (b).



Fonte: O Próprio Autor (2024)

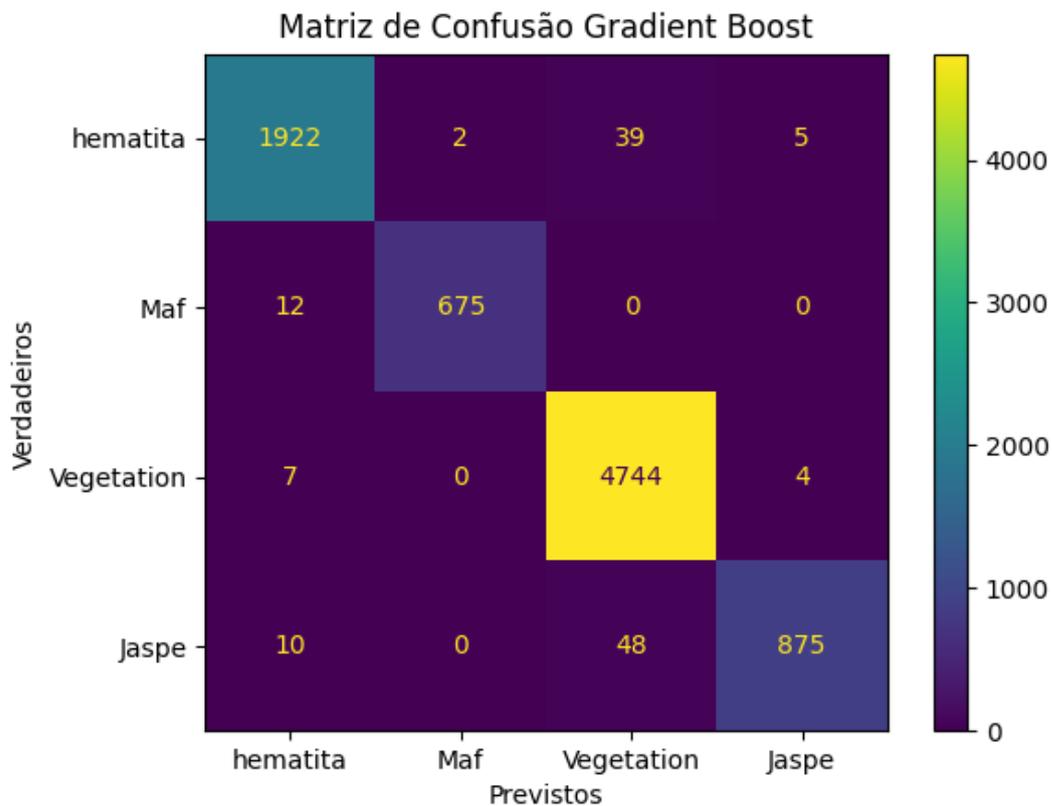
Figura 3.18: Matriz de Confusão – *Random Forest* (20% de amostragem de centros e 30 vizinhos mais próximos).



Fonte: O Próprio Autor (2024).

No caso do algoritmo *Random Forest* (Figura 3.18), em que foi gerada uma matriz de confusão utilizando dados de teste, foram identificados erros significativos na classificação de classes de hematita classificadas como vegetação. Essa situação pode estar relacionada aos pontos de vegetação mais seca e sombreada, com tonalidades de caqui (representando vegetação seca), que se assemelham ao cinza característico da hematita, na escala de cores *RGB*. Além dos erros mencionados, também foram encontrados, por meio da matriz, equívocos na classificação de jaspilitos como vegetação, explicada pela presença de zonas de solo contendo jaspilito nos pontos das classes de vegetação, as quais não puderam ser adequadamente segregadas.

Figura 3.19: Matriz de Confusão – Gradient Boost (20% de amostragem de centros e 30 vizinhos mais próximos).



Fonte: O Próprio Autor (2024).

Em se tratando do *Gradient Boosting*, (Figura 3.19) no qual, assim como na figura anterior foi plotada uma matriz de confusão utilizando-se dados de teste, novamente foram identificados equívocos específicos de falsas previsões de jaspilito e hematita como vegetação, como no caso anterior, que pode ter sido levado pelos mesmos fatores levantados anteriormente, mas também foram verificados erros de outras classes envolvendo o litotipo hematita e jaspilito. O litotipo máfica, de todas as classes, sofreu menor interferência em relação a classificações errôneas com e em outras classes. Isso pode ter ocorrido pela singularidade das cores de máfica e menor de similaridade com as outras classes avaliadas, além da maior delimitação litológica.

Ainda que verificados os erros individuais para ambos os algoritmos avaliados, foram realizadas validações cruzadas espaciais, a fim de verificar se houve a presença *de overfitting* nos casos avaliados. Essa validação manteve os resultados elevados de precisão para ambos os algoritmos, o que valida os métodos estudados.

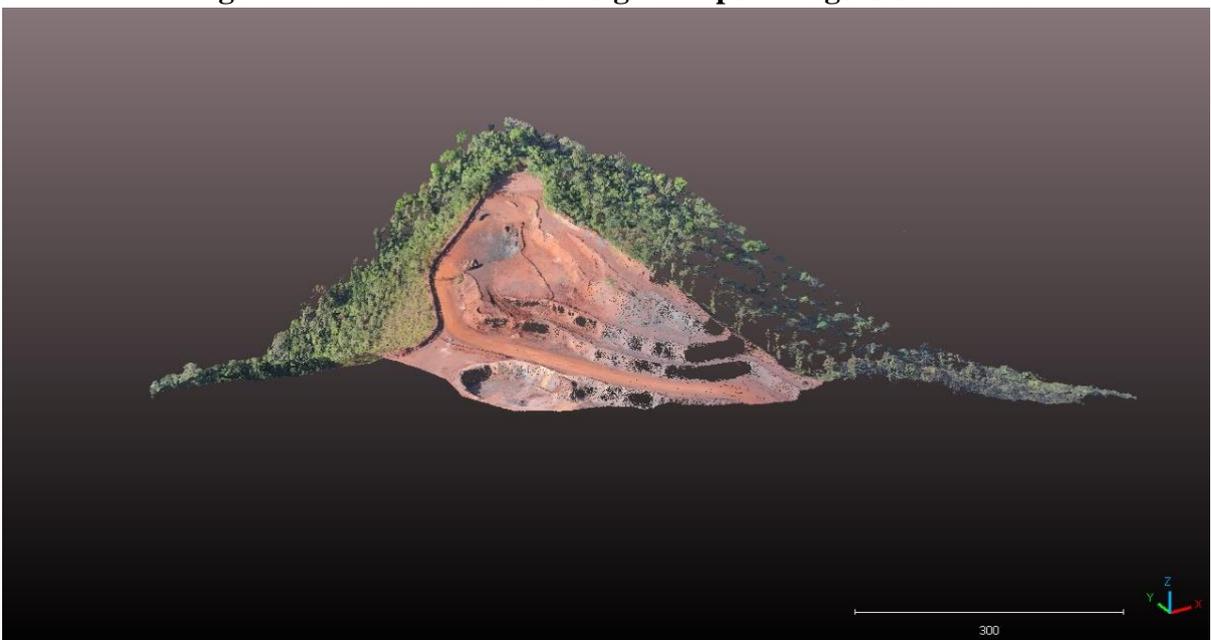
Para validação visual, dos métodos avaliados, todos os modelos foram classificados, de acordo com seus respectivos algoritmos para treinamento, e uma nova nuvem de pontos foi plotada, para comparação com aquela obtida pelas imagens de drone. É mostrado abaixo o resultado para *Random Forest*.

Figura 3.20: Modelo de Pontos Classificado - *Random Forest*.



Fonte: O Próprio Autor (2024).;

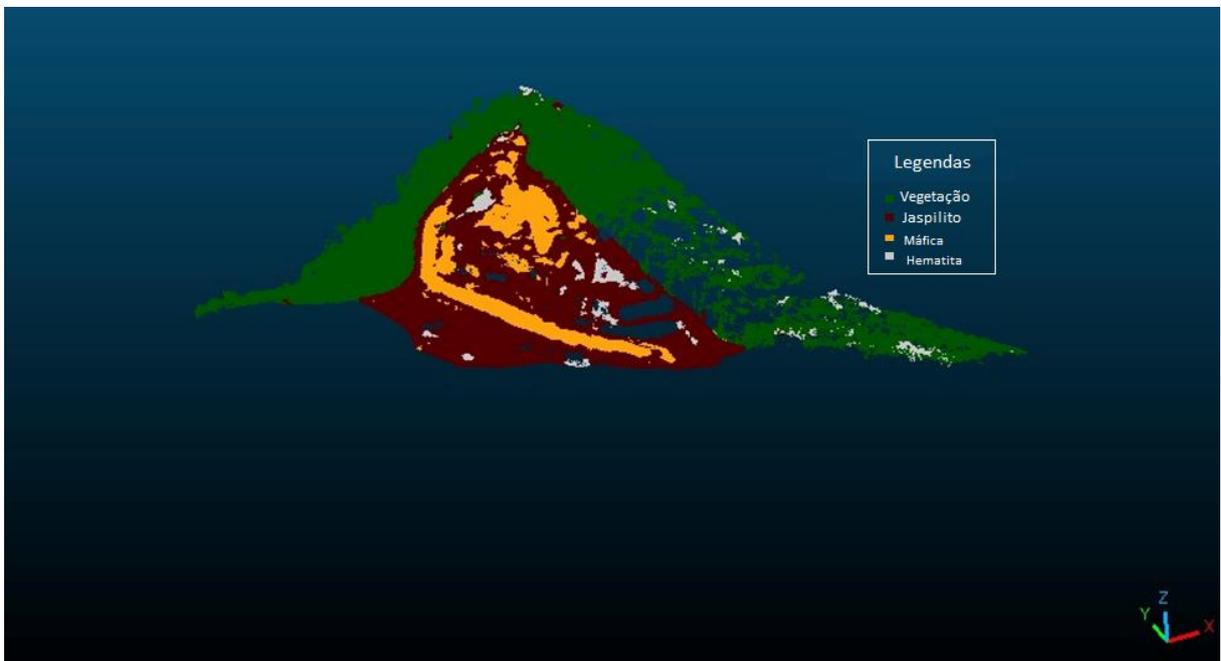
Figura 3.21: Nuvem de Pontos gerada por imagens de VANT.



Fonte: O Próprio Autor (2024).

Foi constatado que o modelo *Random Forest* apresentado gerou uma generalização em algumas áreas, como a região de Hematita na faixa sudeste, que, embora no modelo real apresentasse porções do litotipo, foi totalmente classificada como tal nessa área. Além disso, em algumas regiões de vegetação em que a faixa de solo continha traços não cobertos por espécies vegetais, houve a classificação, de modo integral, como vegetação. Um detalhe importante é a presença de áreas de hematita em parte da região de vegetação, com maior destaque na faixa oeste. Isso ocorreu devido à faixa de vegetação com tonalidade mais acinzentada ou com sombras nas imagens, o que evidencia um possível desafio para esse tipo de análise, que é contornar as diferenças de cores nas diferentes faixas de iluminação.

Figura 3.22: Modelo de Pontos Classificado - SVM.

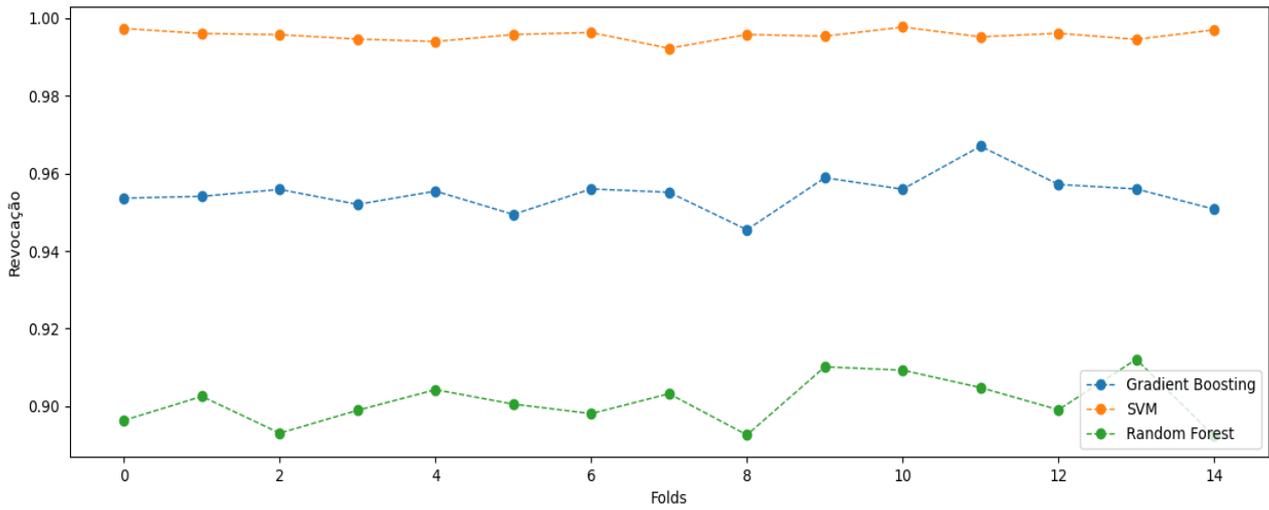


Fonte: O Próprio Autor (2024).

Assim como o modelo *Random Forest*, o modelo gerado por *Support Vector Machine* apresentado gerou uma generalização em algumas áreas, no entanto em maior expressão para a categoria jaspilito. Isso ocorreu devido à faixa de vegetação com tonalidade mais acinzentada ou com sombras nas imagens, o que evidencia um possível desafio para esse tipo de análise, que é contornar as diferenças de cores nas diferentes faixas de iluminação, porém deve-se destacar que ocorreu em menor proporção em relação ao algoritmo *Random Forest*.

Os resultados de validação cruzada demonstraram, para os algoritmos de *Random Forest*, *Gradient Boosting* e *SVM-L* (Figuras 3.23), consistência em relação a cada um dos 15 compartimentos, manifestando média de Revocação próxima uma das outras. Os desempenhos obtidos nos resultados de validação foram superiores aos resultados obtidos pelos dados de treinamento, o que decai uma das possíveis confirmações de *overfitting*.

Figura 3.23: Validação Cruzada Espacial – *Random Forest* – Recall Score.



Fonte: O Próprio Autor (2024).

4. CONCLUSÃO

A aplicação de VANT nas rotinas de classificação litológica de frentes de lavra se mostra uma metodologia eficiente que permite maior dinamismo e frequência, nas classificações, além de maximizar a segurança operacional, diminuindo a exposição humana aos riscos da mineração. Todavia, deve existir uma rotina de classificação visual, ampliando a quantidade de cenários e regiões classificadas, à medida em que a variação litológica e de exposição de frentes de lavra podem variar consideravelmente.

Verificou-se que todos os algoritmos testados apresentaram um aumento no indicador de F1 nos casos em que há menor variação nos litotipos, em comparação com as zonas de contato entre diferentes litotipos. Para esse indicador, assim como para precisão, os algoritmos de *Support Vector Machine*, no geral, apresentaram resultados mais precisos do que aqueles verificados pelos algoritmos *Random Forest* e *Gradient Boosting*.

Os algoritmos *Random Forest* e *Gradient Boosting* apresentaram erros específicos na classificação de certas classes, como vegetação classificada como hematita e, em menor escala, hematita como vegetação. Isso pode ter ocorrido devido à classificação de regiões de vegetação com o solo de hematita, o que sugere a necessidade de classificação de pontos menores com, com uma menor cobertura de espaço.

A validação visual mostrou que o modelo classificado pelo algoritmo *Random Forest* apresentou generalização em algumas áreas, classificando erroneamente certas classes, o que sugere a necessidade de classificações mais distribuídas em várias partes da mina para uma maior representatividade de cores e tons.

Os resultados indicaram que os algoritmos *SVM*, *Random Forest* e *Gradient Boosting* podem ser utilizados de forma eficiente na classificação de litotipos em regiões homogêneas e de contato, mas é importante ajustar corretamente o raio de busca para obter resultados mais precisos e evitar generalizações indevidas. Além disso, é necessário considerar cuidadosamente a distribuição das amostras e a representatividade das cores e tons para uma classificação mais precisa.

A aplicabilidade da técnica explorada deve ser avaliada de caso à caso, a depender do potencial de diferenciação de coloração de litotipos da área avaliada. Máfica, hematita e jaspilito podem ter colorações distintas a depender da mina ou da frente de lavra onde se aplica tal metodologia. Por isso, é fundamental, em todo caso, a presença de um profissional que conheça e saiba identificar os litotipos da área de estudo para uma análise precisa e que garanta a variabilidade e correta determinação de tonalidades e cores.

O ruído de sombreamento e tonalidades poderia ser contornado através da utilização de câmeras hiperspectrais, que pela sua capacidade para discriminar diferentes materiais com base em suas assinaturas espectrais, permitem a identificação de classes com maior precisão. Isso é particularmente útil em áreas com sombreamento, onde a composição litológica pode afetar a refletância da superfície de maneiras que não são facilmente discerníveis em imagens *RGB*. Como câmeras hiperspectrais coletam informações em várias bandas espectrais, elas podem ajudar a reduzir os efeitos do sombreamento.

Um importante ponto a ser avaliado em trabalhos futuros será a resposta desses algoritmos à incorporação de dados de novas frentes de lavra. Como os algoritmos de suporte encontram um hiperplano de separação ótima entre as classes, quando novos dados são adicionados ao modelo *SVM*, geralmente é necessário reajustar o modelo inteiro. Isso significa que devem ser inclusos os novos dados junto aos dados originais de treinamento e ser reexecutado o processo de treinamento *SVM*, o que pode reduzir consideravelmente a performance desses algoritmos. Se tratando dos algoritmos baseados em árvores de decisão, quando novos dados são introduzidos, é possível atualizar um modelo de árvore existente com esses dados sem a necessidade de reajustar o modelo inteiro.

5. REFERÊNCIAS

- ABER, J.S.; RIES, J.B. *Small-Format Aerial Photography*. Alemanha: Elsevier Science, 2010.
- ANDERSON, R. C. 1982. “*Photogrammetry: The Pros and Cons for Archaeology.*” *World Archaeology* v. 14, n. 2, p. 200–205.
- BERETTA, F.; CHIBATA, H.; CORDOVA, R.; PERONI, R.L.; AZAMBUJA, J.; COSTA, J.F.C.L. *Topographic modelling using UAVs compared with traditional survey. methods in mining. REM - International Engineering Journal*, scielo, v. 71, p. 463 – 470, 07 2018. ISSN 2448-167X. Citado 2 vezes nas páginas 51 e 62.
- BERETTA, F.; RODRIGUES, A.L.; PERONI, R.L; COSTA, J.F.C.L. *Automated lithological classification using uav and machine learning on an open cast mine. Applied Earth Science*, Taylor Francis, v. 128, n. 3, p. 79–88, 2019.
- BROWN, R. J.; RUTHEFORD, M. J.; WILLIAMS, A. B. (2020). *Enhanced data processing in unmanned aerial vehicle applications for the mining industry. Mining Engineering Innovations*, 8(3), 52-63.
- BROWN, R. J.; RUTHERFORD, M. J.; IANNACCHIONE, A. T. (2019). Unmanned aerial vehicles in mining: The safety benefits of aerial data. *Mining, Metallurgy & Exploration*, 36(4), 715-722.
- CARVALHO, M.S. *Classificação de Tecidos de Mama a partir de Imagens Mamográficas em Massa e não massa usando índice de diversidade de Mcintosh e Máquinas de Vetores de Suporte*. Dissertação de Mestrado. Programa de Pós- Graduação em Engenharia de Eletricidade. UFMA. Maranhão, 2012.
- CHEN, L.; WANG, H.; ZHANG, T. (2019). *Applications of machine learning in mining. Mining Engineering Innovations*, 7(2), 31-45.
- CHEN, T.; GUESTRIN, C. *Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. ACM, 2016. Citado na página 87.

COSTA, L.; FERNANDEZ, C.; REQUELME, R. O depósito de manganês do Azul, Carajás: Estratigrafia, mineralogia, geoquímica e evolução geológica. DNPM-CT/Mineral- ADIMB. Brasília, 2005.

DA SILVA, P. R. Técnicas de Sensoriamento Remoto e Radiometria Aplicada a Vinhedos em duas regiões do Rio Grande do Sul, Brasil. Dissertação de Mestrado. PGSR. UFRGS, 2006.

DARTNELL, P.; GARDNER, J.V. “*Predicting Seafloor Facies from Multibeam Bathymetry and Backscatter Data,*” *Photogrammetric Engineering & Remote Sensing*, v. 70, n.9, p. 1081 – 1091, 2004. DOI: 10.14358/PERS.70.9.1081. Disponível em: Predicting Seafloor Facies from Multibeam Bathymetry and Backscat...: Ingenta Connect. Acesso em: 25 de Julho de 2022.

ENTERPRISES, E. *Aerial Photogrammetry*. Notas de Curso. Florida: LCC, 2009.

FORTI, M. Técnicas de *Machine Learning* Aplicadas na Recuperação de Crédito do Mercado brasileiro. Dissertação de Mestrado. Escola de Economia. FGV. São Paulo, 2018

FRIEDMAN, J.H. *Stochastic gradient boosting. Computational statistics & data analysis*. 2002

JAMES, G.; WITTEN, D.; HASTIE, T. *An Introduction to Statistical Learning*. Vol. 103. New York, NY: Springer New York; 2014.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSJRANI, R. (2013). *An Introduction to Statistical Learning: With Applications in R*. Springer.

JOHNSON, A. R.; SMITH, C. D. (2022). *Advancements in unmanned aerial vehicle technology for optical data capture. Remote Sensing Innovations*, 15(2), 87-104.

KATZ, D.; FRIESS, M. “*Technical Note: 3D From Standard Digital Photography of Human Crania—A Preliminary Assessment.*” *American Journal of Physical Anthropology* v. 154, n. 1, p. 152–58. USA, 2014. DOI: 10.1002/ajpa.22468. Disponível em: Technical note: 3D from standard digital photography of human crania-a preliminary assessment - PubMed (nih.gov). Acesso em: 29 de Julho de 2022.

KNIJNENBURG, R.; KALANTARI, N. K.; BAIER, F. "Advances in Structure from Motion: Bridging the Gap Between Photogrammetry and Computer Vision". *Journal of Photogrammetric Engineering & Remote Sensing*, 2021.

- LEE, T. R.; CHEN, C. F. (2018). *Integration of technology and industrial operations: Concept, opportunities and challenges*. *Procedia CIRP*, 72, 313-318.
- LI, R.; BELFORD, G. *Instability of decision tree classification algorithms*. In *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining*, ACM, 2002. 10, 12.
- LIIIESAND, T.; KIEFER, R.; CHIPMAN, J. *Remote Sensing and Image Interpretation*. ed. 7. Wiley, 2004.
- LORENA, A.C.; DE CARVALHO, A.C.P.L. *As Máquinas de Vetores de Suporte (Support Vector Machines)*. São Paulo: USP, Junho de 2002.
- LOVELACE, R.; NOWOSAD, J.; MUENCHOW, J. *Statistical Learning: Spatial CV, Geocomputation with R*. 2021.
- MOHRI, M.; ROSTAMIZADEH, A.; TALWAKAR, A. *Foundations of Machine Learning*. ed. 1. Cambridge: EUA, 2012.
- MONTEIRO, L.V.S.; XAVIER, R.P.; FILHO, C.R.S.; MORETO, C.P.N. *Metalogênese de Carajás. Metalogênese das Províncias Tecnônicas Brasileiras*. CPRM, Belo Horizonte, 2008.
- PERONI, R. L., *Aplicações de Mapeamento e Modelagem de Terreno com Uso de VANTs em Áreas de Mineração*. Relatório de Pós Doutorado, UFSC. 2017.
- ROBEDIZO, B. P. “*The Identifiability of Osteological Traits on 3D Models of Human Skeletal Remains*.” Tese de Doutorado. Lunds Universitet. Suécia, 2016.
- SANTOS, J.O.S., 2003. *Geotectônica do Escudo das Guianas e Brasil-Central*. Geologia, Tectônica e Recursos Minerais Do Brasil. CPRM-Serviço Geológico do Brasil, Brasília.
- SCHENK, T. *Introduction to Photogrammetry*. Ohio: Autumn, 2005.
- SENHORINHO, S.A.C. *Metodologia de Planejamento Estratégico de Lavra Incorporando Riscos e Incertezas para a Obtenção de Dados Operacionais*. In: Tese de Doutorado, Escola Politécnica de São Paulo, São Paulo, Brasil. São Paulo, 2008.
- SMITH, A. B.; JOHNSON, C. D. *Wearable devices and real-time hazard detection using machine learning in mining operations*. *Journal of Occupational Safety and Health Innovations*, 6(3), 189-203, 2021.

SOKOLOVA, M.; LAPALME, G. *A systematic analysis of performance measures for classification tasks. Information Processing & Management*, 2009.

SZELISKI, R. *Computer Vision: Algorithms and Applications*. 2022.

UNHAMMER, O. F. "Methodological Evaluation of Digital Photogrammetry in a Middle Stone Age Cave Context. A Case Study from Blombos Cave, South Africa." Tese de Doutorado. The University of Bergen. Noruega, 2016.

VALE. Resumo do Relatório Técnico: Complexo Serra Norte. Brasil, 2021. Disponível em: <[ef4499f7-7656-1fac-64ae-6b2203435f4c \(mziq.com\)](https://mziq.com/ef4499f7-7656-1fac-64ae-6b2203435f4c)>

VAPNIK, V.N. *Statistical Learning Theory*. New York: Wiley, 1998.

VASQUEZ, M.L.; ROSA-COSTA, L.T. Geologia e Recursos Mineirais do Estado do Pará: Sistema de Informações Geográficas - SIG: texto explicativo dos mapas Geológico e Tectônico e de Recursos Minerais do Estado do Pará, 1a. ed. CPRM, Belém, 2008.

WROBEL, D.; BIGGS, J.; HAIR, A. "Digital Modeling for Bioarchaeologists." *Advances in Archaeological Practice*. v. 7, n. 1, p. 47–54. USA, 2019. DOI: <https://doi.org/10.1017/aap.2018.47>. Disponível em: (1) *Digital Modeling for Bioarchaeologists* | Request PDF ([researchgate.net](https://www.researchgate.net)). Acesso em: 29 de Julho de 2022.

XU, X.; ZHANG, H.; LI, S. "Deep Learning Approaches to Multiple Sterile Matching in Stereo Vision". *IEEE Transactions on Image Processing*, 2020.

ZHANG, Y.; KANG, J.; LI, Y. "Non-Orthophoto Image Processing for Environmental Monitoring Using Deep Learning". *Remote Sensing*, 2023.