



**UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
DEPARTAMENTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
EM CIÊNCIAS DA TERRA E DO AMBIENTE**



RAFAEL OLIVEIRA FRANCA ROCHA

**APLICAÇÕES GEOLÓGICAS DE SENSORIAMENTO REMOTO NA
PESQUISA DO POTENCIAL MINERAL PARA FERRO**

FEIRA DE SANTANA - BA

2022

RAFAEL OLIVEIRA FRANCA ROCHA

**APLICAÇÕES GEOLÓGICAS DE SENSORIAMENTO REMOTO NA
PESQUISA DO POTENCIAL MINERAL PARA FERRO**

Dissertação apresentada ao Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente (PPGM), da Universidade Estadual de Feira de Santana como requisito parcial para obtenção de título de Mestre em Ciências Ambientais.

Orientação: Prof. Dr. Carlos Moreira de Souza Júnior

Coorientação: Prof. Dr. Rodrigo Nogueira de Vasconcelos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001

FEIRA DE SANTANA - BA

2022

RAFAEL OLIVEIRA FRANCA ROCHA

**APLICAÇÕES GEOLÓGICAS DE SENSORIAMENTO REMOTO
NA PESQUISA DO POTENCIAL MINERAL PARA FERRO**

Dissertação apresentada ao Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente (PPGM), da Universidade Estadual de Feira de Santana como requisito parcial para obtenção de título de Mestre em Ciências Ambientais.

Orientação: Prof. Dr. Carlos Moreira de Souza Júnior

Coorientação: Prof. Dr. Rodrigo Nogueira de Vasconcelos

Data de aprovação: 01 de setembro de 2025

Prof. Dr. Carlos Moreira de Souza Júnior

Instituto do Homem e Meio Ambiente da Amazônia -IMAZON
(orientador)

Documento assinado digitalmente



RODRIGO NOGUEIRA DE VASCONCELOS
Data: 01/09/2025 16:24:48-0300
Verifique em <https://validar.itd.gov.br>

Prof. Dr. Rodrigo Nogueira de Vasconcelos
Universidade Estadual de Feira de Santana - UEFS
(coorientador)

Documento assinado digitalmente



PEDRO WALFIR MARTINS E SOUZA FILHO
Data: 01/09/2025 14:26:11-0300
Verifique em <https://validar.itd.gov.br>

Prof. Dr. Pedro Walfir Martins e Souza Filho
Universidade Federal do Pará -UFPA
(Banca examinadora)

Documento assinado digitalmente



TATI DE ALMEIDA
Data: 01/09/2025 14:53:47-0300
Verifique em <https://validar.itd.gov.br>

Prof. Dra. Tati de Almeida
(Universidade de Brasília - UNB)
(Banca examinadora)

Ficha Catalográfica – Biblioteca Central Julieta Carteado

R576a Rocha, Rafael Oliveira Franca
Aplicações geológicas de sensoriamento remoto na pesquisa do potencial mineral para ferro./ Rafael Oliveira Franca Rocha.- 2022.
68f.: il.

Orientador: Carlos Moreira de Souza Júnior
Coorientador: Rodrigo Nogueira de Vasconcelos

Dissertação (mestrado) – Universidade Estadual de Feira de Santana. Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente, 2022.

1.Sensoriamento remoto. 2.Inteligência artificial. 3.Geologia
4.Minério de ferro – Bahia I.Souza Júnior, Carlos Moreira de, orient.
II.Vasconcelos, Rodrigo Nogueira de, coorient. III.Universidade
Estadual de Feira de Santana. IV.Título.

CDU: 553.31(814.2)

Maria de Fátima de Jesus Moreira – Bibliotecária – CRB5/1120

RESUMO

O estado da Bahia é um dos maiores produtores de recursos minerais do Brasil, graças a geodiversidade de seu território, que possibilita a extração de uma grande variedade de tipos de minérios. Entretanto, apesar dessa proeminência, o setor de produção mínero-industrial para o ferro não contribui significamente para essa posição de destaque, mesmo possuindo depósitos potencialmente mineiros, conhecidos através de inúmeros levantamentos geológicos efetuados nos últimos 80 anos. O conhecimento científico encontra-se disperso nos meios de publicação, enquanto dados quantitativos e qualitativos sobre os depósitos de ferro estão indisponíveis, decorrente do valor estratégico para as empresas que investiram seus recursos para obtê-los, sendo uma pequena parcela disponibilizada pelos órgãos públicos de pesquisa mineral. Dentro deste cenário, estratégias como a bibliometria na análise e sistematização de estudos científicos sobre a utilização de sensoriamento remoto na avaliação de minérios pode ser promissora em termos da produção de uma análise crucial e sistemática da literatura e da concessão de subsídios que conduzam à construção de informação sobre o mapeamento de jazidas de minério de ferro. E, novos métodos de integração, como os algoritmos de *machine learning*, apresentam potencial para alcançar uma precisão maior na delimitação de zonas de interesse mineral. Desta forma, este trabalho tem como objetivo contribuir para o mapeamento de ocorrências de minerais ferrosos no estado da Bahia. O estudo está dividido em dois capítulos. O primeiro capítulo consiste em uma análise bibliométrica, através de técnicas de mineração de texto, para reconhecer padrões na literatura que possam servir de base para analisar estatisticamente os resultados dos diferentes estudos sobre o mapeamento de jazidas ferríferas, com o objetivo de avaliar as tendências metodológicas nesse campo de atuação. O segundo capítulo trata da aplicação de um método de aprendizagem de máquina em imagens de sensoriamento remoto. A utilização de dados auxiliares, como pontos de ocorrência mineral, geologia e áreas de requerimentos minerários foram utilizados para otimizar o gerenciamento dos resultados e permitindo seu uso eficaz como diretriz no processo de pesquisa mineral. Espera-se obter um conhecimento do potencial mineral da Bahia em relação aos minérios de ferro, assim reforçando a ampla aplicabilidade dos dados de sensoriamento remoto no setor da exploração mineral, permitindo classificar uma extensa região de acordo com seu grau de aproveitamento econômico, através da análise dos dados disponíveis.

Palavras-chave: sensoriamento remoto, inteligência artificial, minério de ferro, geologia

ABSTRACT

The state of Bahia is one of the largest producers of mineral resources in Brazil, thanks to the geodiversity of its territory, which enables the extraction of a wide variety of mineral types. However, despite this prominence, the mining-industrial production sector for iron does not contribute significantly to this prominent position, even though it has potentially minable deposits, known through countless geological surveys carried out in the last 80 years. The scientific knowledge is dispersed in the means of publication, while quantitative and qualitative data about the iron deposits are unavailable, due to the strategic value for the companies that have invested their resources to obtain them, and a small part is made available by the public organs of mineral research. Within this scenario, strategies such as bibliometry in the analysis and systematization of scientific studies on the use of remote sensing in ore evaluation may be promising in terms of producing a crucial and systematic analysis of the literature and providing subsidies that lead to the construction of information on the mapping of iron ore deposits. And, new integration methods, such as machine learning algorithms, have the potential to achieve greater accuracy in delineating areas of mining interest. Thus, this work aims to contribute to the mapping of ferrous mineral occurrences in the state of Bahia. The study is divided into two chapters. The first chapter consists of a bibliometric analysis, through text mining techniques, to recognize patterns in the literature that can serve as a basis for statistically analyzing the results of different studies on the mapping of ferrous deposits, to evaluate methodological trends in this field of action. The second chapter deals with the application of a machine learning method to remote sensing images. The use of auxiliary data, such as mineral occurrence points, geology and mining requirement areas were used to optimize the management of the results and allowing their effective use as a guideline in the mineral research process.

Keywords: remote sensing, artificial intelligence, iron ore, geology

LISTA DE FIGURAS

Figura 1 – Distritos ferríferos do estado da Bahia segundo Ribeiro (2017).

Figura 2 – Fluxograma da metodologia, expondo as diferentes etapas de trabalho e atividades envolvidas.

Figura 3 – Evolução anual da quantidade de publicações ao longo do tempo para as combinações.

Figura 4 – Evolução anual da quantidade de publicações ao longo do tempo. A linha vermelha sinaliza a tendência de comportamento dos dados do gráfico.

Figura 5 – Gráfico de participação dos países de origem dos artigos levantados e sua frequência de publicação ao longo das décadas.

Figura 6 – Evolução temporal da participação dos países de origem dos artigos publicados e sua relação de co-citação.

Figura 7 – Rede de co-autoria. As diferentes cores (clusters) e espessura das linhas indicam a interação entre os autores e seu nível de intensidade. Os diferentes tamanhos das fontes demonstram a quantidade de publicações e suas colaborações.

Figura 8 – Rede de co-ocorrência dos termos referentes aos temas e metodologias mais utilizadas dentre os artigos pesquisados. As diferentes cores (clusters) e espessura das linhas indicam, respectivamente, a frequência de ocorrência nas publicações e o nível de intensidade das relações.

Figura 9 – Rede de co-ocorrência dos termos referentes às metodologias mais utilizadas entre os artigos pesquisados em um intervalo temporal.

Figura 10 – Rede de co-ocorrência dos termos referentes às ferramentas e bases de dados geológicos e de sensoriamento remoto mais utilizadas dentre os artigos pesquisados.

Figura 11 – Preços do minério de ferro de 2003 a 2012 (em dólares americanos por unidade de tonelada métrica seca) (Fonte: Wårell, 2018).

Figura 12 – Preços do minério de ferro de 2000 a 2022 (em dólares americanos por unidade de tonelada métrica seca) (Fonte: Reuters, 2022)

Figura 13 – Mapa de localização da área de estudo sobreposta a imagem SRTM sombreada, destacando os estratos de amostragem na Mina Pedra de ferro (A) e Mina Mocó (B), os estratos de classificação e a geologia simplificada.

Figura 14 – Fluxograma da metodologia, expondo as diferentes etapas de trabalho e atividades envolvidas.

Figura 15 – Gráficos de dispersão dos pontos de pixels representativos de minério, solo, mistura solo/vegetação e vegetação extraídos da imagem nos estratos: (0) zona da área das minas (100) buffer de 100m das áreas das minas, (200) buffer de 200m das áreas das minas, (500) buffer de 500m da área das minas e (1000) buffer de 10km, representando distâncias maiores que 500m das áreas das minas.

Figura 16 – Assinatura mediana de pixels representativos de minério, solo, mistura solo/vegetação e vegetação extraídos da imagem nos estratos: (0) zona da área das minas (100) buffer de 100m das áreas das minas, (200) buffer de 200m das áreas das minas, (500) buffer de 500m da área das minas e (1000) buffer de 10km, representando distâncias maiores que 500m das áreas das minas.

Figura 17 – Gráficos bloxpot dos pontos de pixels representativos de minério, solo, mistura solo/vegetação e vegetação extraídos da imagem nos estratos: (0) zona da área das minas (100) buffer de 100m das áreas das minas, (200) buffer de 200m das áreas das minas, (500) buffer de 500m da área das minas e (1000) buffer de 10km, representando distâncias maiores que 500m das áreas das minas

Figura 18 – Gráficos da semelhança dos valores médios das classes com a biblioteca espectral X zona de distância (estratos de amostragem).

Figura 19 – Mapa de potencialidade para ferro na área de estudo

Figura 20 – Mapa de potencialidade para ferro na área de estudo sobreposta a imagem SRTM sombreada, destacando os pontos de depósitos conhecidos e as poligonais de requerimentos de lavra e de pesquisa

Figura 21 – Comparação das áreas de concessão de lavra com imagens de alta resolução (Google). (A) Mina Pedra de Ferro, (B) Mina Mocó, (C) Mina vanádio de Maracás (Largo), (D) Mina Andorinha e (E) Mina Caraíba

Figura 22 – Mapa de potencialidade para Fe no distrito ferrífero do sudoeste da Bahia.

Figura 23 – Mapa de potencialidade para Fe no distrito ferrífero do norte da Bahia.

Figura 24 – Mapa de potencialidade para Fe e os requerimentos de pesquisa mineral.

LISTA DE TABELAS

Tabela 1 – Tabela da relação de publicações levantadas e selecionadas de acordo com a combinação de diferentes palavras-chave.

Tabela 2 – Tabela da relação de influência dos autores de acordo com as publicações levantadas e selecionadas e número de citações.

Tabela 3 – Tabela da relação de influência dos autores de acordo com as publicações levantadas e selecionadas e número de citações.

Tabela 4 – Tabela da relação dos estratos de amostragem, utilizados para os dados de entrada (input) e os estratos de classificação, utilizados como zonas de controle para a classificação supervisionada.

Tabela 5 – Tabela da matriz de confusão das classes de potencialidade

SUMÁRIO

CAPÍTULO I – INTRODUÇÃO GERAL

1.1 INTRODUÇÃO.....	1
1.2 OBJETIVO GERAL.....	4
1.3 OBJETIVOS ESPECÍFICOS.....	4

REFERÊNCIAS BIBLIOGRÁFICAS.....	5
---------------------------------	---

CAPÍTULO II

2.1 INTRODUÇÃO	6
2.2 METODOLOGIA	8
2.2.1 Base de dados bibliográficos.....	8
2.2.2 Filtragem e revisão.....	9
2.2.3 Análises das redes.....	10
2.3 RESULTADOS	11
2.3.1 Países ou territórios com publicações mais representativas.....	13
2.3.2 Principais autores e instituições.....	15
2.3.3 Metodologias mais utilizadas.....	17
2.3.4 Ferramentas, bases geológicas e de dados de sensoriamento remoto mais utilizadas.....	20
2.4 DISCUSSÃO	21
2.5 CONCLUSÕES.....	27
REFERÊNCIAS BIBLIOGRÁFICAS.....	29
ANEXOS.....	32

CAPÍTULO III

3.1 INTRODUÇÃO	34
3.2 METODOLOGIA.....	37
3.2.1 Área de estudo.....	37
3.2.2 Desenho amostral.....	38
3.2.3 Biblioteca espectral e índices.....	40
3.2.4 Análise de indícios (potencial) de mineralização.....	42
3.3 RESULTADOS.....	45
3.3.1 Comportamento espectral.....	45
3.3.2 Análise Minimum Noise Fraction (MNF) e Spectral Angle Mapper (SAM).....	48
3.3.3 Classificação Random Forest.....	49
3.3.4 Validação.....	52
3.4 DISCUSSÃO	57
3.5 CONCLUSÕES	60
REFERÊNCIAS BIBLIOGRÁFICAS.....	61
ANEXOS.....	67
CAPÍTULO IV – CONCLUSÃO GERAL	
4.1 CONSIDERAÇÕES E RECOMENDAÇÕES FINAIS	68

Capítulo I

1.1 INTRODUÇÃO

Desde a Idade Antiga, o desenvolvimento da humanidade esteve interligado aos materiais metálicos, especificamente os minerais ferríferos, pelos seus aspectos industriais. A ampla utilização do ferro pela civilização, substituindo o bronze que era, até então, a liga metálica mais utilizada na época, iniciou a partir de 1200 A.C, conhecida comumente como a Idade do Ferro. Segundo Navarro (2006), essa mudança ocorreu por ser uma substância relativamente abundante, mais fácil de manipular do que o cobre e o estanho e gerava produtos de qualidade superior. Ainda hoje, o ferro é um dos metais mais demandados mundialmente, como principal componente para fabricação do aço, liga metálica presente em diversos segmentos de objetos.

O Brasil, atualmente, é o segundo maior produtor mundial de minério de ferro, responsável por 16% das exportações da indústria extractiva do mineral (BRASIL, 2022). Os principais estados produtores são Minas Gerais e Pará que, juntos, correspondem a 98% da produção de minério de ferro nacional. Os 2% restantes estão divididos entre os estados de Mato Grosso do Sul, Bahia, Goiás, Maranhão, Ceará e Rio Grande do Norte.

O estado da Bahia é o quarto maior produtor de ferro do país com um valor de, aproximadamente, 0,016% do total de ferro produzido no país (SDE, 2022). A reserva mais significativa do estado está associada as sequências metavulcanossedimentares arqueanas /paleoproterozóicas próximo ao município de Caetité (Alkmim *et al.*, 2007), onde a mais expressiva ocorrência está localizada na Mina Pedra de Ferro (Bamin Mineração), maior mina de ferro em operação do estado, com 948 milhões de toneladas certificados e teores de até 62%. Outra importante reserva compreende as formações ferríferas do Complexo Santa Luz, onde está localizada a Mina Jacuípe (Ferrous Resources do Brasil), próximo do município de Coração de Maria, com 1,12 bilhão de toneladas certificadas e teor médio de 27,22%.

Entretanto, ao analisar o histórico da exploração e pesquisa de ferro na Bahia (Leonardos, 1937; Santana *et al.*, 1974; Souza *et al.*, 1979), pode-se inferir que o potencial metalogenético ferrífero do estado é ainda maior. Um levantamento realizado pela Companhia Baiana de Pesquisa Mineral (CBPM) (Ribeiro, 2017), estimou que existem pelo menos 12,5 bilhões de toneladas de ferro ainda não explorados, distribuídos em pelo menos cinco distritos ferríferos no estado (Figura 1), a exemplo das formações ferríferas bandadas do Complexo Colomi, localizados nos municípios de Sento Sé e Remanso, ao norte do estado, com 5 bilhões de toneladas estimados e teores variando entre 26% e 66%.

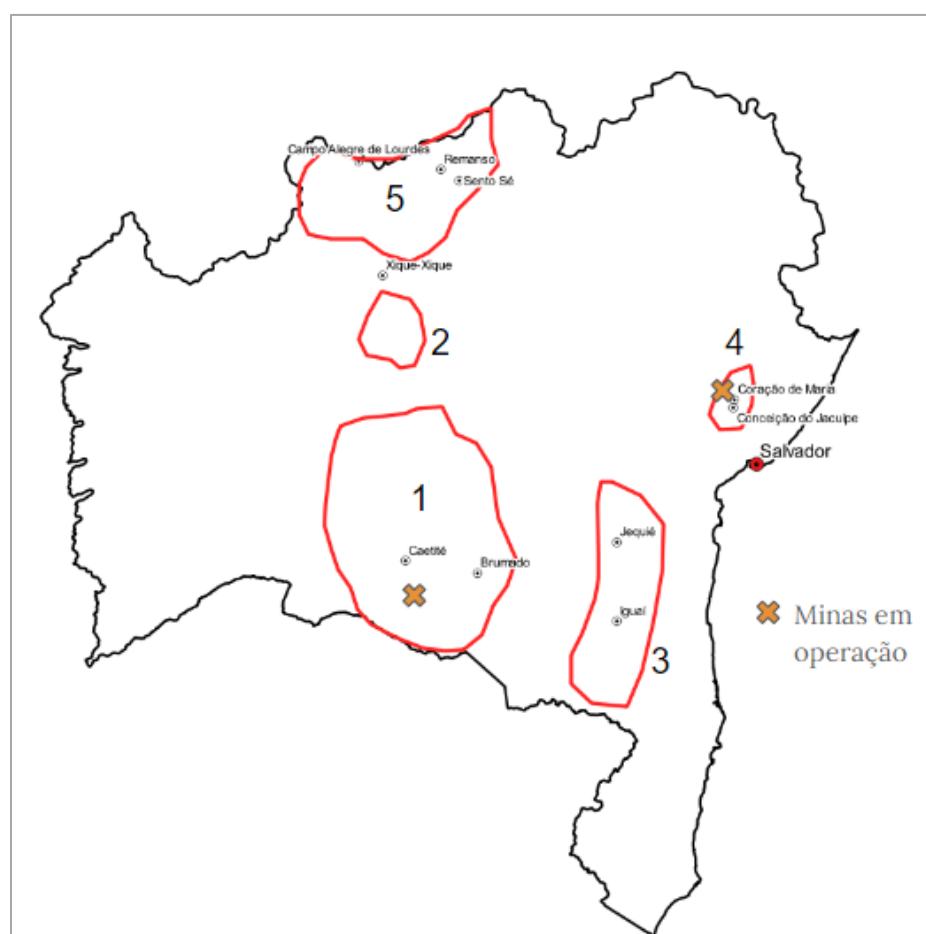


Figura 1 – Distritos ferríferos do estado da Bahia segundo Ribeiro (2017). **1)** Distrito do Sudoeste da Bahia (Depósitos de Caetité-Brumado. Certificados: 948Mt / Estimados 5,21Bt - teores entre 32% e 62%). **2)** Distrito do Médio São Francisco (Depósitos de Xique-Xique. Estimados: 430Mt - teor médio: 24,8%). **3)** Distrito Sudeste da Bahia (Depósitos de Iguai-Jequié. Estimados 513Mt - teores entre 29% e 39%). **4)** Distrito do Recôncavo (Depósitos de Coração de Maria-Conceição do Jacuípe. Estimados 1,13Bt - teor médio 27,7%). **5)** Distrito do Norte da Bahia (Depósitos de Campo Alegre de Lourdes). Estimados 5,0Bt - teores entre 26% e 66%).

Desde a crise da economia causada pela pandemia do Covid-19, países como a China, antes consumidora de cerca de 70% do ferro mundial (Thorne, 2020), aumentaram significativamente a demanda pelo metal no processo de recuperação econômica, tornando o momento oportuno para a descoberta de novas jazidas.

A partir do entendimento da dimensão da problemática da demanda por recursos minerais, existe uma busca da sociedade científica por métodos e técnicas capazes de diagnosticar e identificar os depósitos minerais com maior precisão, dentre as quais o Sensoriamento Remoto, que possui ferramental de grande notoriedade. Sensoriamento remoto corresponde ao conjunto de técnicas que objetivam medir as características físicas de um objeto sem tocá-lo (Silva, 2003). A interpretação de imagens de sensores remotos fundamenta-se, basicamente, na análise do comportamento da reflectância espectral dos materiais.

Para a execução desse trabalho, é proposta a organização em dois capítulos com formato de artigos científicos. O primeiro capítulo consiste na revisão bibliográfica através do levantamento e análise de publicações científicas e artigos de referência sobre o sensoriamento remoto aplicadas ao mapeamento superficial de minerais metálicos. Espera-se identificar na literatura as tendências metodológicas e os avanços conceituais na abordagem da temática ao longo do tempo. Essa etapa é importante porque fornece uma base para os próximos capítulos, à medida que direciona os estudos, com base nos principais indicadores e técnicas mais utilizadas no mundo. A metodologia desse capítulo fundamenta-se na utilização da base de dados Scopus, para gerar dados quantitativos e qualitativos em forma de redes de correlação, tabelas e gráficos.

O segundo capítulo objetiva mapear áreas com potencialidade para prospecção mineral de ferro em toda extensão do estado da Bahia com a seleção dos sensores, fontes de dados e integração com métodos de *Machine Learning* baseados na disponibilidade das informações. Dentre os dados acessíveis, estão coleções de imagens do sensor Sentinel-2, disponível na plataforma Google Earth Engine (Gorelik *et al*, 2017), assim como o poder de processamento de computação em nuvem da Google Cloud. Como datasets de treinamento e validação, informações de mapas de referências como a geologia e geodiversidade estão disponíveis no Serviço Geológico Brasileiro (CPRM). Na Companhia Baiana de Pesquisa Mineral (CBPM), pode-se

obter a localização geográfica de mineralizações de ferro em áreas de ocorrência já conhecidas. Etapas de campo em áreas de ocorrência de ferro conhecidas, dentro dos distritos ferríferos delimitados pelos trabalhos de Santana et al. (2017), para coleta de amostras, podem fornecer dados de assinatura espectral dos minérios de ferro.

Espera-se, com este trabalho, ao responder as seguintes perguntas norteadoras: Quais são as bases de dados de sensoriamento remoto que fornecem os melhores vetores para prospecção mineral? Quais os sensores que apresentam maior potencial para identificar formações ferríferas? É possível identificar, com uma certa precisão, rochas mineralizadas em ferro em todo o território baiano, com a integração desses dados por meio de técnicas de *Machine Learning*?

1.2 OBJETIVO GERAL

Avaliar as ferramentas para geração de vetores na exploração mineral para ferro, por meio da análise bibliométrica, no intuito de desenvolver um modelo de potencialidade mineral com base em dados de sensoriamento remoto e métodos tecnológicos processados em nuvem.

1.3 OBJETIVOS ESPECÍFICOS

- Identificar publicações de maior referência em pesquisa de ferro
- Definir uma base de dados para o modelo de potencialidade para ferro.
- Definir *datasets* de treinamento e de validação para identificar padrões espectrais dos minérios de ferro.
- Aplicar o modelo de potencialidade na identificação de novos alvos de ferro no Estado da Bahia e validação do modelo.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALKMIM, F. F., PEDROSA-SOARES, A. C., NOCE, C. M., CRUZ, S.C.P. **Sobre a evolução tectônica do Orógeno Araçuaí-Congo Ocidental.** Geonomos, 15 (1), 25–43. 2007.
- BRASIL, Secretaria de Geologia, Mineração e Transformação Mineral (DTTM), Ministério de Minas e Energia (MME). **Boletim do Setor Mineral – Abril de 2022.** 3º Edição, Brasília, 2022, 32p.
- DALTON DE SOUZA, J.; FERNANDES, F. J.; GUIMARÃES, J. T.; LOPES, J. N. 1979. **Projeto Colomi; geologia da região do Médio São Francisco,** Salvador, CPRM. convênio DNPM/CPRM. 3v.
- GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D., & MOORE, R. 2017. **Google Earth Engine: Planetary-scale geospatial analysis for everyone.** *Remote Sensing of Environment.*
- LEONARDOS, O. H. **Ferro no Estado da Bahia. Mineração e Metalurgia,** Rio de Janeiro, v. 2, n. 7, p. 51-57, maio/jun. 1937.
- NAVARRO, R.F, **A Evolução dos Materiais. Parte 1: da Pré-História ao inicio da Era Moderna.** Revista Eletrônica de Materiais e Processos. Universidade Federal de Campina Grande v.1, 2006, pp. 01-11.
- RIBEIRO, A.F., **Potencialidade do minério de ferro no estado da Bahia.** Salvador, Bahia. 102 p.: il. color. Série publicações especiais; 20, ISBN 978-85-85680-61-9. Companhia Baiana de Pesquisa mineral, CBPM, 2017.
- SANTANA, A.J. et al. **Projeto cadastramento de ocorrências minerais do estado da Bahia:** área II - Juazeiro. Salvador: SME; CPM, v. 2. 1974.
- SANTANA, W. R. R. et al. **Projeto de avaliação estratégica dos distritos de minério de ferro da Bahia.** Salvador: CBPM, 2017. Relatório interno.
- SOUZA, J. D. de et al. **Projeto Colomi: relatório final: geologia e prospecção geoquímica da região de Remanso-Sento Sé.** Salvador: CPRM, 1979. 10 v.
- SILVA, A.B. **Sistemas de Informações Geo-referenciadas: Conceitos e fundamentos.** Livro texto , 1ª Ed 2003, UNICAMP, Campinas, SP, 236p.
- THORNE.T, Perspectivas para a Indústria de minério de ferro e aço. **REFINITIV,** 2020. Disponível em: < <https://www.refinitiv.com/pt/blog/trading/perspectivas-para-a-industria-de-minerio-de-ferro-e-aco/>>. Acesso em 18 out. 2020.



Capítulo II

APLICAÇÕES GEOLÓGICAS DE SENSORIAMENTO REMOTO NA PESQUISA DO POTENCIAL MINERAL PARA FERRO: UMA ANÁLISE BIBLIOMÉTRICA.

2.1 INTRODUÇÃO

A pesquisa mineral corresponde a um campo da geologia responsável pelo mapeamento geológico de substâncias minerais economicamente relevantes de acordo com o seu aproveitamento industrial (Brasil, 2018). Dentre essas técnicas de levantamento geológico, temos a utilização de dados de sensoriamento remoto que contribuem de forma suplementar aos estudos de descoberta e avaliação de jazidas (Bonham-Carter, 1994), fornecendo bons resultados e novas perspectivas com baixo custo operacional aos métodos tradicionais de prospecção mineral. (Rajesh, 2004).

Existe uma quantidade considerável de publicações, no meio científico, de aplicações de uso de sensoriamento remoto na pesquisa mineral. Na sua maioria, estão relacionadas com o uso de imagens de satélites multiespectrais, hiperespectrais ou de radar na caracterização de contatos entre unidades geológicas (definidos ou inferidos) e no mapeamento de áreas potencialmente mineralizadas para mineração [Ciampalini *et al.* (2013), Feizi & Mansouri. (2013), Van der Meer *et al.* (2014), Silva *et al.* (2016), Shirazi *et al.* (2018), Ourhzif *et al.* (2019)], com alguns trabalhos voltados para uma revisão da popularização do sensoriamento remoto na área das geociências [Coulter *et al* (2017), Wu *et al* (2018), Bedini (2022)]. No entanto, existe uma falta na comunidade científica mostrando uma visão geral das técnicas e

tendências compiladas sistematicamente para um bem mineral específico, uma vez que as interpretações estruturais, litológicas, metalogenéticas e de controle de minério incorporadas no modelo prospectivo variam de acordo com a substância e o seu grau de alteração (Deb & Kaur, 2008) e, desta forma, podem influenciar no tipo de dado de sensoriamento remoto utilizado, bem como na metodologia de geoprocessamento abordada. Portanto, para nortear uma visão mais extensa com o objetivo de contemplar e compreender os padrões de desenvolvimento inexplícitos neste campo de investigação, a bibliometria pode ser um recurso útil.

A bibliometria pode ser definida como uma análise da pesquisa bibliográfica baseada em ferramentas matemáticas e estatísticas para selecionar e averiguar publicações, citações, periódicos em muitas disciplinas e campos de estudo (Santana *et al.*, 2021). Segundo Vasconcelos *et al.* (2020) Sua metodologia consiste na identificação de publicações e de seus autores através de palavras-chaves, associadas a um tema em questão e realiza uma análise qualitativa e quantitativa para extrair tendências de investigação, podendo ser expressos em forma de redes de mapeamento, relacionando essa base de dados de acordo com termos extraídos do título, resumo ou palavra-chave (co-palavra); colaboração intelectual de diferentes autores, organizações ou países (co-autoria); ou entre a correlação de citações entre manuscritos (co-citação).

Nesse sentido, esse trabalho objetiva realizar uma análise bibliométrica das publicações científicas com uso de dados de sensoriamento remoto para o mapeamento de litologias mineralizadas em ferro ao longo do tempo. Para melhor abordagem sobre esse tema, pretende-se responder as seguintes questões: i) Quais as metodologias de processamento digital de imagens e modelagem de dados mais utilizadas? ii) Quais os dados de sensoriamento remoto e de fatores geológicos de controle de minério mais frequentes nas publicações? iii) Quem são os autores e entidades que mais publicam sobre o tema? iv) Quais os países com publicações mais representativas?

2.2 METODOLOGIA

A metodologia proposta está organizada em três fases, as duas primeiras são compostas por um sinalizador condicional, o que significa que a próxima fase só poderá ser iniciada, se as condições da fase anterior forem aceitáveis. Esse processo é importante porque fornece uma visão equacionada, à medida que direciona as etapas envolvidas no estudo, assegurando uma análise e sistematização mais robusta das informações. A primeira fase consiste no levantamento bibliográfico, de acordo com as questões norteadoras da pesquisa, através da seleção dos critérios de busca. A segunda fase consiste na filtragem da base de dados, selecionando apenas as publicações pertinentes ao estudo. Por fim, a terceira fase compreende a representação dos resultados e as análises realizadas para responder as perguntas propostas anteriormente.

2.2.1 Base de dados bibliográficos

A plataforma de busca acadêmica escolhida para o levantamento bibliográfico foi o *Scopus*, por estar entre os maiores bancos de dados de publicações científicas multidisciplinares (Gusenbauer, 2019) e por possuir ferramentas adicionais de análise e compilação de informação, como rankings de publicações e de revistas acadêmicas, perfis de autores com cálculos de produtividade e impacto, com possibilidade de exportação de dados para múltiplos formatos (Elsevier, 2022).

A seleção das palavras-chave foi efetuada de forma a compreender o mapeamento de formações ferríferas em toda extensão mundial, com a seleção dos tipos de sensores, fontes de coleções de imagens e métodos de processamento digital de imagens e modelagem de dados, incluindo metodologias de classificação baseadas em algoritmos de inteligência artificial, especificamente o aprendizado de máquina (*Machine Learning*), que apesar de não estar contemplado na ciência do sensoriamento remoto, representa uma nova tendência nos estudos de construção de modelos prospectivos (Ye *et al*, 2018). A estratégia de pesquisa para a seleção das palavras-chave teve como foco o objetivo de selecionar apenas os artigos que tratavam do estudo geológico para óxidos de ferro com uma metodologia que envolvesse sensoriamento remoto. Essas publicações poderiam envolver a aplicação direta do sensoriamento remoto para a identificação de rochas mineralizadas em

ferro, bem como trabalhos que efetuações uma revisão das técnicas de sensoriamento remoto na geologia. Essa pesquisa se deu através das seguintes etapas: Apenas artigos contendo as palavras “remote sensing” e “iron” localizadas no título, ou resumo, ou nas palavras-chave do resumo ou especificadas pelo autor foram considerados. Para a lógica de consulta, foram testados diferentes arranjos de termos e operadores booleanos até chegar às combinações mais abrangentes para o âmbito do estudo, ou seja, que englobassem a maior quantidade possível de artigos relacionados com o tema e com o mínimo possível de publicações não relevantes. Por fim, foram selecionados somente trabalhos do tipo artigo e em estágio final de publicação, para reduzir falsos positivos ao evitar a duplicação de artigos, caso tenham sido publicados em outras fontes, como simpósios, congressos ou capítulos de livros.

2.2.2 Filtragem e revisão

Ainda no ambiente *Scopus*, a primeira fase da filtragem consistiu na exclusão dos artigos não correspondentes ao tema de pesquisa. Para isso, foram incluídos parâmetros restritivos para selecionar apenas os artigos pertencentes as categorias das áreas das ciências exatas e de caráter multidisciplinar, como as ciências ambientais.

Uma primeira conferência visual foi efetuada, com leitura de cada título dos artigos pesquisados para identificar as publicações de maior referência com os objetivos do estudo e os mais citados. Em seguida, foi realizada uma leitura de cada resumo para destacar os estudos mais relevantes para leitura completa e para excluir os artigos em que a pesquisa realizada não fosse considerando o mapeamento geológico de minerais óxidos de ferro, embora, tenha sido incluído na base, artigos abordando pesquisas em que a prospecção é voltada para minerais de alteração hidrotermal e minérios sulfetados que podem estar enriquecidos em ferro, no caso da mineração de cobre, ouro e os depósitos de ferro-titânio-vanádio.

A partir desse ponto, foi montado um banco de dados, composto pelas bases de artigos selecionadas pelas combinações de palavras-chave que conseguiram incluir todas as publicações consideradas relevantes na etapa anterior. Ao baixar essas bases da plataforma *Scopus*, foram extraídas as seguintes informações: títulos,

palavras-chave do resumo, autores principais, co-autorias, instituições e organizações, países, ano de publicação, frequência de citações, referências e o código de identificação (DOI). Por fim, para identificar os padrões de distribuição das diferentes metodologias aplicadas e dados de sensoriamento remoto utilizados, foi realizada uma categorização das tabelas exportadas do Scopus em formato csv, utilizando o *software* Microsoft Excel, para compartimentar os artigos de acordo com o tipo de contexto geológico envolvido na ocorrência do minério, localidade, método aplicado e fonte do instrumento de sensoriamento remoto. Essas edições são suplementares a metodologia bibliométrica, mas permitem uma melhor estrutura para auxiliar na construção das redes de co-palavra e co-citação.

A tabela abaixo (tabela 1) sintetiza as etapas envolvidas nesta fase.

Tabela 1 – Tabela da relação de publicações levantadas e selecionadas de acordo com a combinação de diferentes palavras-chave.

Palavras-chave	Total de artigos pesquisados	Total de artigos selecionados	Período dos artigos selecionados
"Geological" AND "Dataset" AND "mineral exploration" AND "Machine Learning" AND "Remote Sensing"	41	5	2016-2021
"Remote Sensing" AND "Iron Oxides"	373	125	1977- 2021
"Machine Learning" AND "Iron Oxides" AND "Geology"	25	5	2019 – 2021
"Iron deposits" AND "Iron ore" OR "Geology" AND "remote sensing" OR "Learning systems" OR "artificial intelligence" OR "Data integration"	128	42	1981 – 2021
Total de publicações pós-filtragem	567	177	1977-2021

2.2.3 Análises das redes

A construção das redes foi efetuada pelo *software* VOSViewer. Para as redes de co-palavra, os critérios de análise incorporaram a inserção do arquivo modificado thesaurus e a escolha dos parâmetros de visualização obedeceram aos seguintes limites: dois para o número mínimo de ocorrências de uma palavra-chave, trinta e

quatro para o número de palavras-chave selecionadas para o cálculo de intensidade de conexão das co-ocorrências, método de contagem inteira e com a inclusão das palavras-chave “indexadas” e “citadas pelo autor”. Essa abordagem permitiu visualizar a evolução do conhecimento científico, identificando os diferentes nichos de pesquisa, de acordo com sua área de atuação.

As redes de co-citação utilizaram três para o número mínimo de citações de uma referência, noventa para o número de fontes selecionadas para o cálculo de intensidade de conexão das co-citações, método de contagem fracionada e “fontes citadas” como unidade de análise. Esses critérios foram escolhidos para reduzir o tamanho da rede e para equacionar os artigos com maior contribuição na identificação dos padrões de pesquisa, ao selecionar as citações com os métodos e tópicos mais frequentes na pesquisa de ferro.

O fluxograma metodológico (Figura 1) ilustra as fases e etapas envolvidas nesse trabalho.

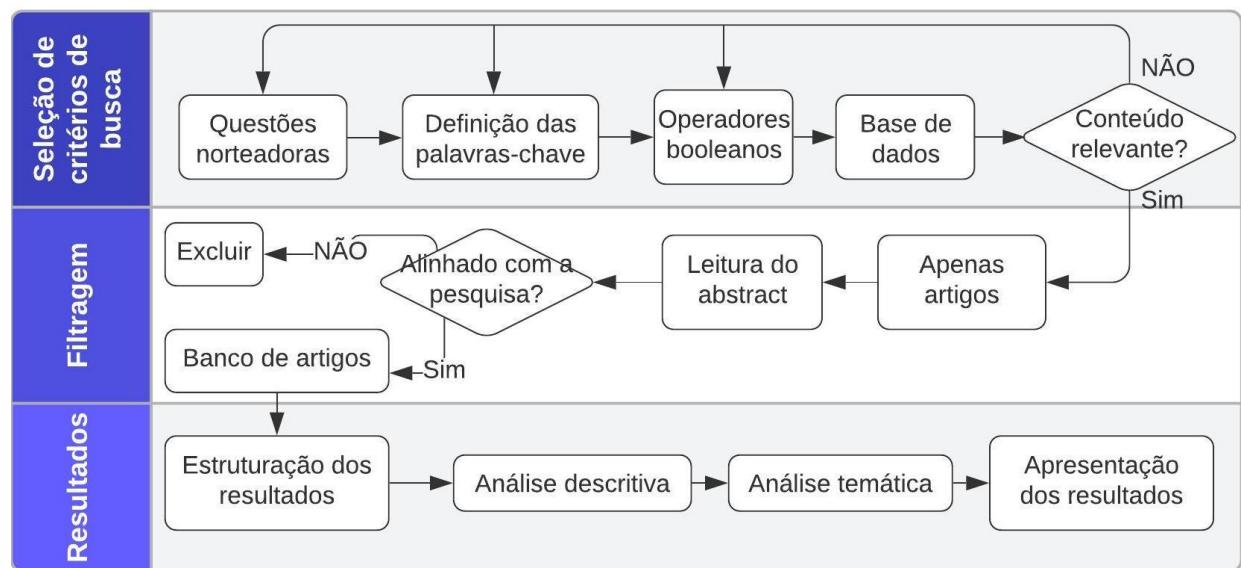


Figura 2 – Fluxograma da metodologia, expondo as diferentes etapas de trabalho e atividades envolvidas.

2.3 RESULTADOS

Um total de 567 artigos foram extraídos após examinar a base do *Scopus*, dos quais, 390 foram rejeitados por não envolver temáticas de sensoriamento remoto no

mapeamento de ferro, resultando em uma quantidade final de 177 artigos publicados em um período entre 1977 e 2021.

A figura abaixo (Figura 2) mostra o comportamento da evolução anual da quantidade de publicações por cada combinação de palavras-chave separadamente.

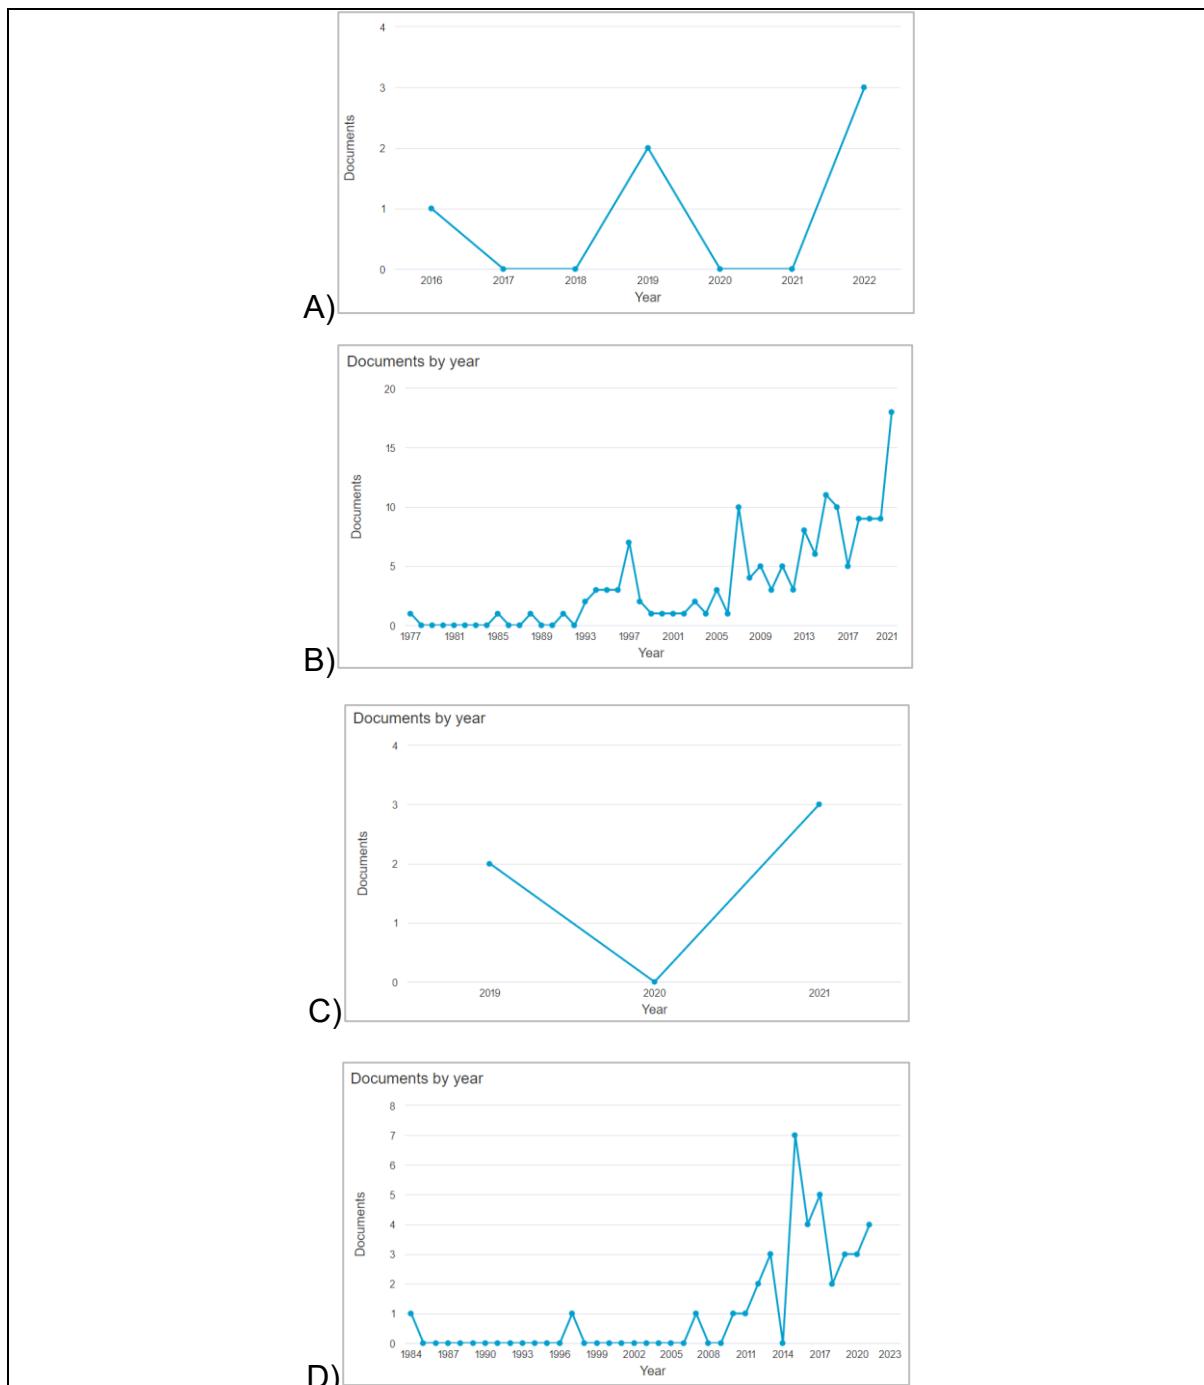


Figura 3 – Evolução anual da quantidade de publicações ao longo do tempo para as combinações. A) "Geological" AND "Dataset" AND "mineral exploration" AND "Machine Learning" AND "Remote Sensing". B) "Remote Sensing" AND "Iron Oxides". C) "Machine Learning" AND "Iron Oxides" AND "Geology". D) "Iron deposits" AND "Iron ore" OR "Geology" AND "remote sensing" OR "Learning systems" OR "artificial intelligence" OR "Data integration".

A partir da base final de artigos, foi possível efetuar o gráfico do número de publicações anuais (Figura 4), onde observou-se pouca variabilidade na quantidade de artigos nos primeiros trinta anos do período definido (entre 1977 e 2006) e, a partir de 2007, um crescimento considerável. É notável, também, a existência de anos que se destacam pela grande quantidade de publicações, como 1977, 1984, 1997 e 2019, assim como os que apresentaram uma quebra na cadência, com um número bem reduzido de artigos, quando comparados com os anos vizinhos, exemplo de 2006, 2015, 2016, 2020 e 2021. Dentre as publicações selecionadas, 55% estão associados a área das ciências da terra, 10,6% a área da geofísica, 10,5% a área das ciências computacionais, 9,5% a área das engenharias, 8,6% as ciências ambientais e os 5,8% restantes, estão divididos em publicações nas áreas das ciências dos materiais, sociais, agricultura e matemática.

Ao observar a Figura 3, podemos notar que as publicações referentes as combinações de palavra-chave envolvendo metodologias de *machine learning* começaram a aparecer somente na segunda metade da década de 2010. De acordo com os gráficos, houve um decrescimento de número de artigos em 2020, seguido de uma retomada de publicações nos anos seguintes



Figura 4 – Evolução anual da quantidade de publicações ao longo do tempo. A linha vermelha sinaliza a tendência de comportamento dos dados do gráfico.

2.3.1 Países ou territórios com publicações mais representativas

Uma informação extraída dos artigos pesquisados foi o país de origem das publicações. Foram identificados 16 países com trabalhos publicados ao longo período de 1977 a 2021 (Figura 5). De antemão, é notável a disparidade da quantidade de artigos no período entre 2010 e 2019, comparado com as outras décadas. Outra informação interessante é que apesar do período de 2020 e 2021 apresentar menor volume de publicações em relação a década anterior, somente nesses dois anos já foi possível superar o total de artigos produzidos na década de 2000, com uma quantidade de 29 trabalhos, contra 26 publicações no período entre 2000 e 2009. Os países que mais se destacam são, por ordem decrescente: a Australia, com 33 publicações; China, com 29; Iran, com 23; Brasil, com 21 e Índia, com 20. Alguns países se destacaram por apresentarem um pico de publicações somente em um período específico, como os Estados Unidos e o Reino Unido, que foram os países/territórios que mais publicaram nas três últimas décadas do século XX, o Canadá, que teve seus picos entre 1990 e 2010, junto com a Alemanha e o Egito, que teve grande destaque na década de 2010. Outros países, como a África do Sul, Algéria, Chile, Itália, Malásia e Rússia não tiveram uma quantidade significativa de publicações, mas contribuíram com o tema da pesquisa.

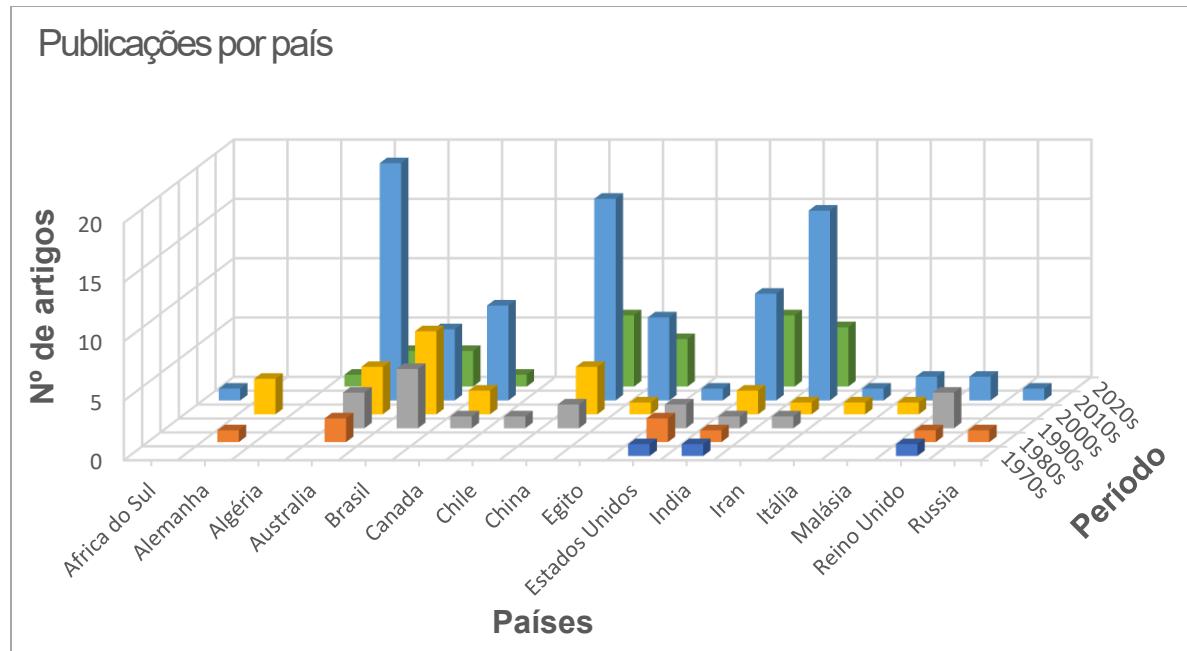


Figura 5 – Gráfico de participação dos países de origem dos artigos levantados e sua frequência de publicação ao longo das décadas.

No que se refere a relação de citação das publicações entre as nacionalidades, temos a figura abaixo (Figura 6), que ilustra as tendências do relacionamento entre os países.

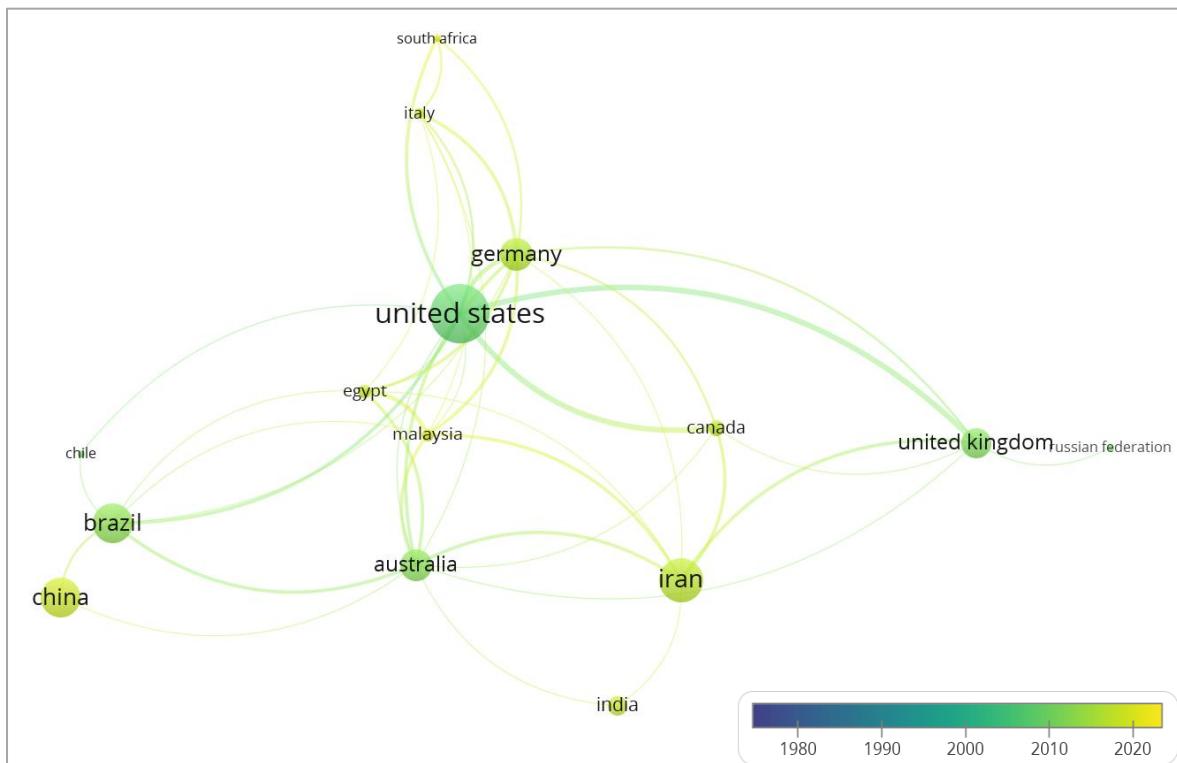


Figura 6 – Evolução temporal da participação dos países de origem dos artigos publicados e sua relação de co-citação.

Foi possível observar que até o início do século XXI, países como os Estados Unidos, Brasil, Australia e Reino Unido ocupavam a centralidade de referência na produção de pesquisas sobre o tema abordado. Esse panorama mudou após 2010, quando países como a China e o Irã começaram a ganhar notoriedade.

2.3.2 Principais autores e instituições

Para a análise de co-autoria, foram gerados mapas de redes com enfoque apenas para os autores em que suas publicações fossem especificamente voltadas para pesquisa em ferro (Figura 7), resultando em 19 publicações. A partir daí, foi possível sintetizar em forma de tabela (Tabela 2 e Tabela 3) com o ranking dos autores e instituições mais relevantes com suas respectivas quantidades de citações em outros trabalhos.

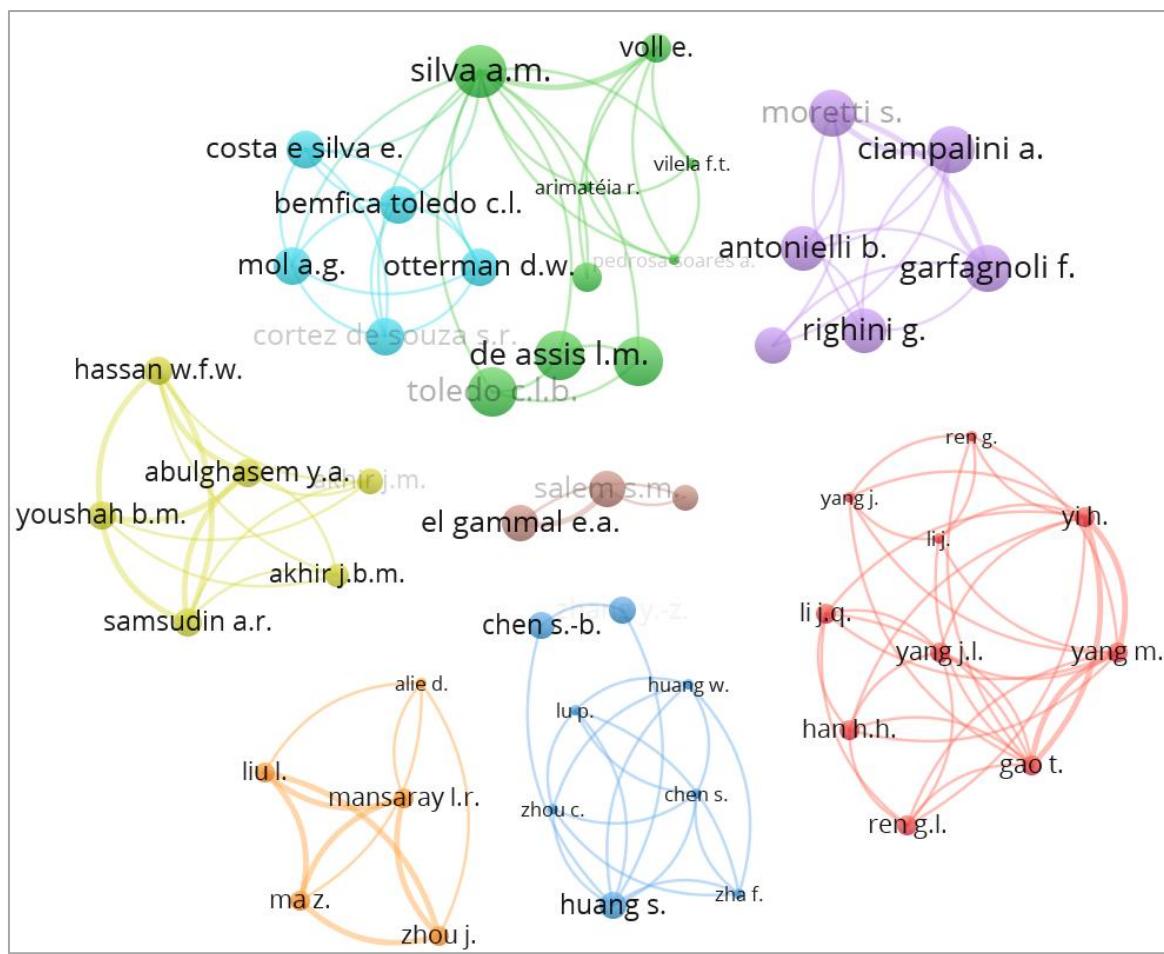


Figura 7 – Rede de co-autoria. As diferentes cores (clusters) e espessura das linhas indicam a interação entre os autores e seu nível de intensidade. Os diferentes tamanhos das fontes demonstram a quantidade de publicações e suas colaborações.

Tabela 2 – Tabela da relação de influência dos autores de acordo com as publicações levantadas e selecionadas e número de citações.

Colocação	Autores	Nº de Publicações	Nº de Citações
1	Silva, A.M.	4	89
2	Mol, A.G.	3	78
3	Ciampalini, A.	2	56
4	El Gammal, E.A.	2	16
5	Huang, S.	2	16
6	Abulghasem, Y.A.	2	5
7	Gao, T.	2	3
8	Liu, L.	2	3

Com base nos resultados, é possível notar a que a China e Brasil estão na frente das publicações de uso de sensoriamento remoto na pesquisa mineral. Dos

dez colocados mais influentes, temos países como Austrália, Itália, Egito e Malásia, menos expressivos na quantidade de publicações, porém com boa quantidade de citações.

Tabela 3 – Tabela da relação de influência dos autores de acordo com as publicações levantadas e selecionadas e número de citações.

Colocação	Autores	Nº de Publicações	País
1	Chinese Academy of Sciences	14	China
2	Universidade de São Paulo	11	Brasil
3	Universidade de Brasília	4	Brasil
4	University of Sydney	4	Austrália
5	Università degli Studi di Firenze	2	Itália
6	National Authority for Remote Sensing And Space Sciences	2	Egito
7	Jilin University	2	China
8	Universiti Kebangsaan Malaysia	2	Malásia
9	China Geological Survey	2	China
10	Chang'an University	2	China

2.3.3 Metodologias mais utilizadas

Os mapas de co-ocorrência das metodologias utilizadas nas análises dos dados de sensoriamento remoto e informações geológicas selecionaram 150 termos com mais de 10 repetições extraídos dos dados textuais dos títulos, resumos e palavras-chave das informações bibliográficas. Após a remoção e/ou unificação de temas similares, restaram 26 termos que foram utilizadas para a construção da rede de relação de co-ocorrência mais presentes nos artigos científicos pesquisados (Figura 8).

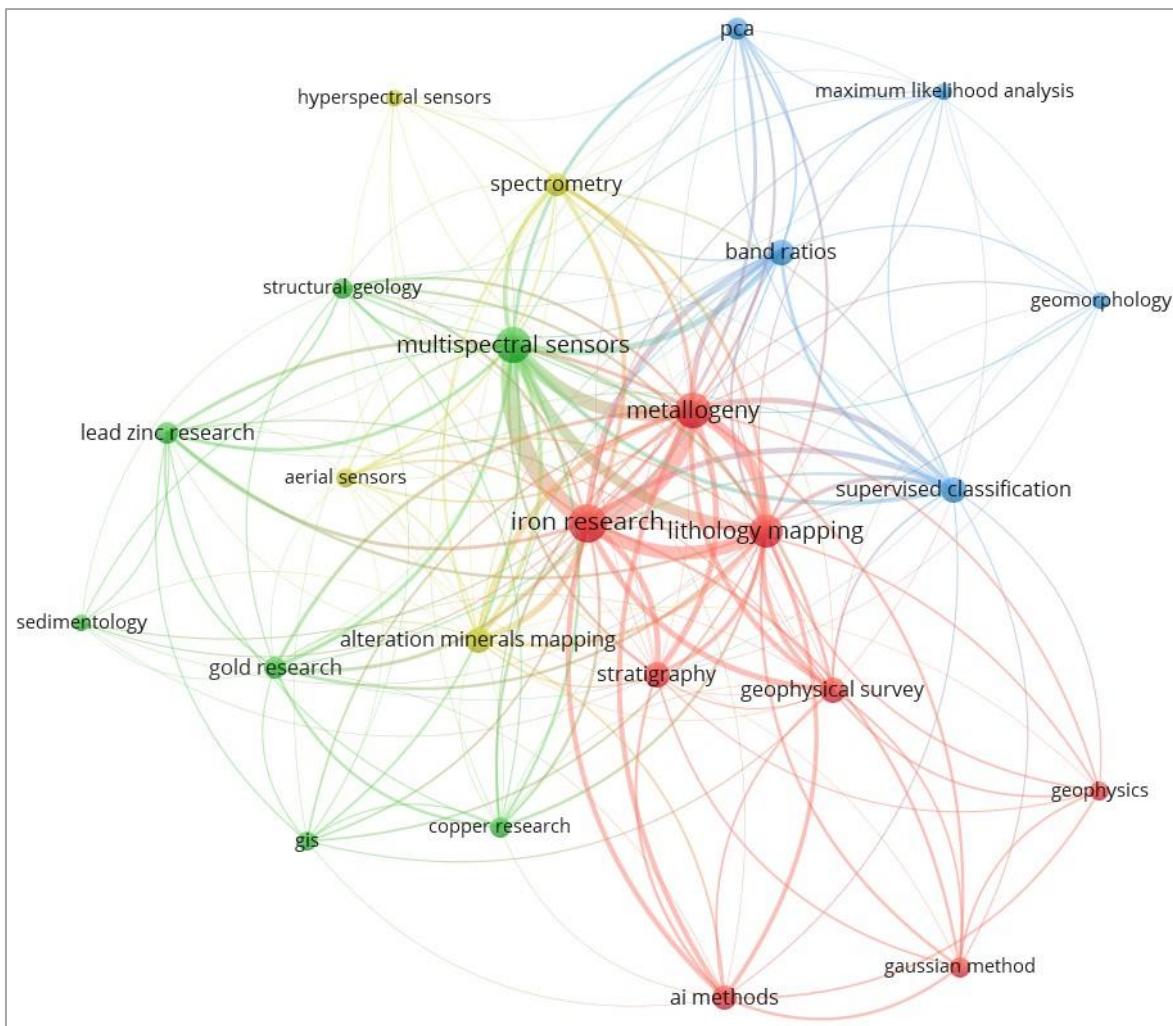


Figura 8 – Rede de co-ocorrência dos termos referentes aos temas e metodologias mais utilizadas dentre os artigos pesquisados. As diferentes cores (clusters) e espessura das linhas indicam, respectivamente, a frequência de ocorrência nas publicações e o nível de intensidade das relações.

Foi observada a separação dos termos em quatro clusters, com destaque para o alto nível de intensidade da relação entre a pesquisa em ferro e o mapeamento litológico voltado para a metalogênese com o uso de imagens de sensores multiespectrais. As bases propostas envolvem a detecção de depósitos de ferro através de levantamentos geofísicos para o mapeamento litoestratigráfico com o uso de técnicas de inteligência artificial e modelagens estatísticas gaussiana de assimilação, observados no cluster vermelho. No cluster azul, temos a análise de imagens de satélite com classificação supervisionada e não-supervisionada (*Principal Component Analysis- PCA*) com utilização de razão de bandas e técnicas de inferência estatística, como o *Maximum Likelihood Estimation (MLE)*, com o uso de informações geomorfológicas. O cluster amarelo consiste no mapeamento de minerais de alteração com análises de espectrometria, com a utilização de imagens

de sensores hiperespectrais de satélites e aéreos. O cluster verde revela a pesquisa indireta de ferro com a compilação de sistemas de informações geográficas e análises de sensores multiespectrais, com a utilização de estudos de sedimentologia e de geologia estrutural.

A evolução dessas informações ao longo do tempo foi evidenciada no mapa de redes entre os termos selecionados (Figura 9), onde foi possível notar que as metodologias mais frequentes até 2014, eram aplicadas à sensores multiespectrais com levantamentos geofísicos, geomorfológicos, utilizando análises com o MLE. A maior parte dos outros termos estão localizados no período entre 2015 e 2017, com a aparição mais recente dos estudos envolvendo imagens aéreas e análises sedimentológicas a partir de 2018.

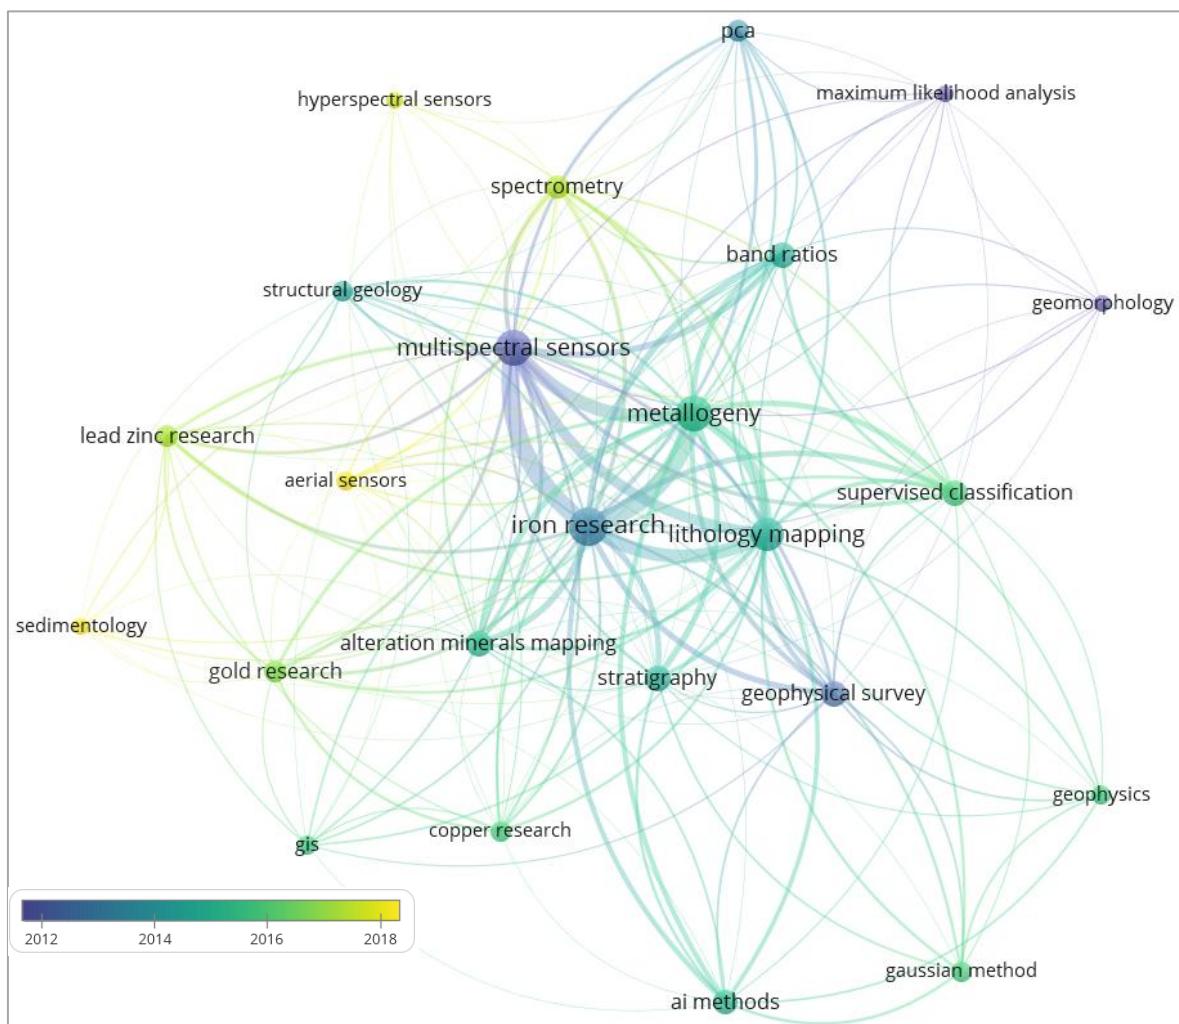


Figura 9 – Rede de co-ocorrência dos termos referentes às metodologias mais utilizadas entre os artigos pesquisados em um intervalo temporal.

2.3.4 Ferramentas, bases geológicas e de dados de sensoriamento remoto mais utilizadas

Para a tendência sobre as bases de dados mais utilizadas para a pesquisa em ferro, a análise realizada no VOSViewer retornou 249 termos, classificados em seis clusters, evidenciados no mapa de frequência de co-ocorrência da relação dos termos que mais aparecem nos artigos publicados (Figura 10).

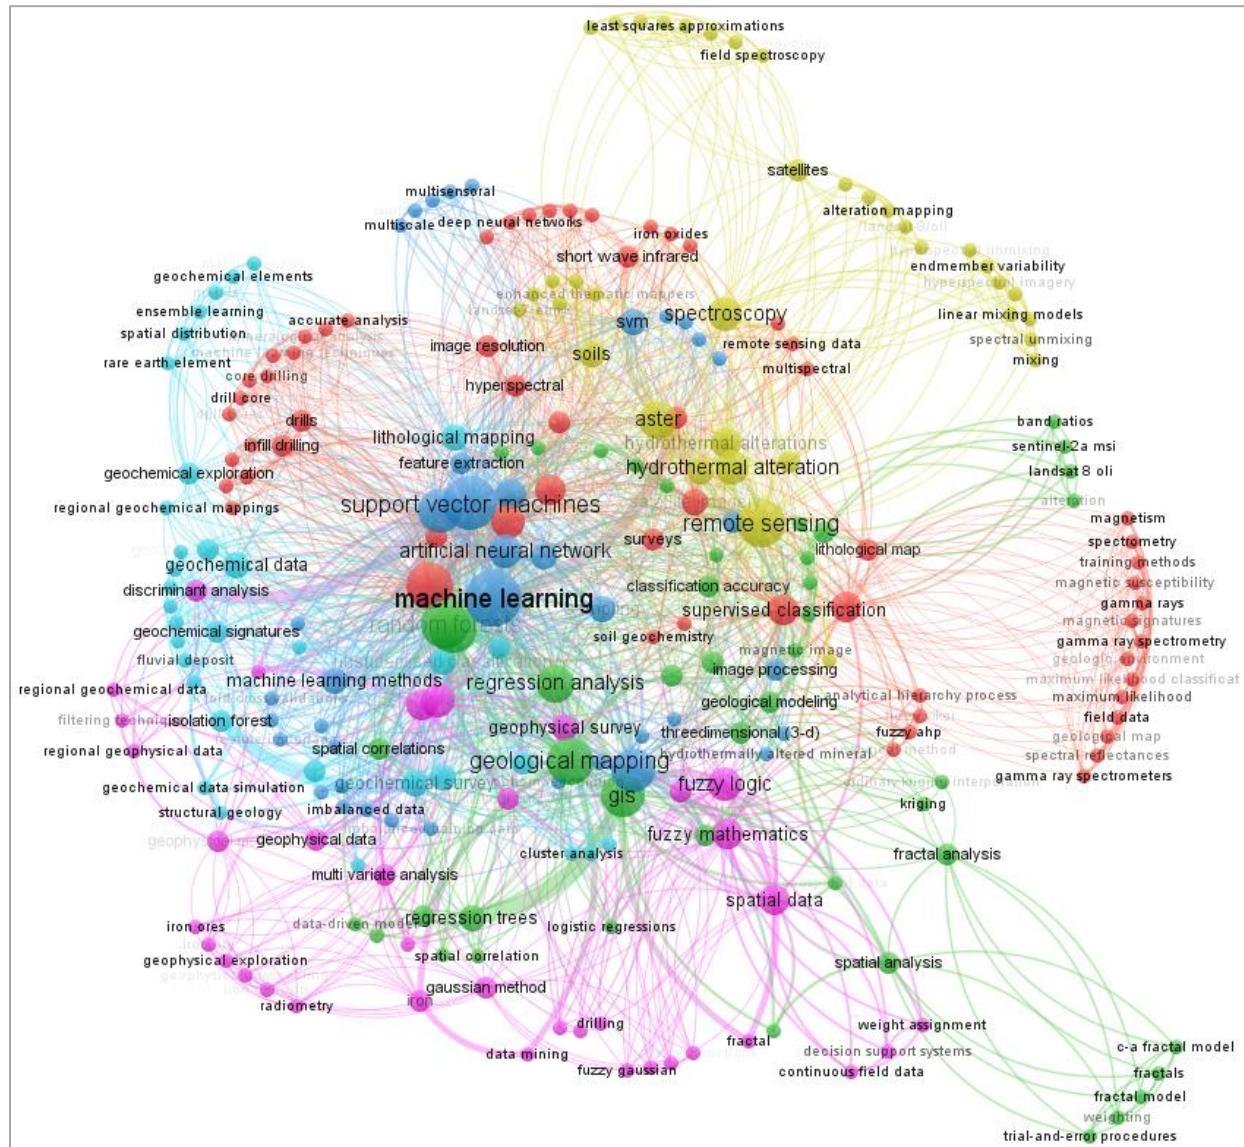


Figura 10 – Rede de co-ocorrência dos termos referentes às ferramentas e bases de dados geológicos e de sensoriamento remoto mais utilizadas entre os artigos pesquisados.

Algoritmos de *Machine Learning* e de inferência estatística se destacaram ao ter bastante frequência dentre as ferramentas mais citadas e o uso de imagens dos sensores Landsat (5, 7 e 8), Sentinel 2-A, Aster e Hyperion estão incluídas em todos os clusters de bases de dados. Dentre os conjuntos de dados geológicos observados,

percebe-se a utilização de informações geofísicas para o mapeamento estratigráfico, estrutural e de comportamento magnético para uma detecção de áreas mineralizadas. Foi observado o uso de dados geoquímicos, em conjunto com dados de amostras de rocha e solo, para avaliar o comportamento geoquímico do ferro e de outros elementos associados, bem como identificar níveis de teores das ocorrências minerais. Entretanto, é notável o grande destaque para o uso de dados de geologia espectral integrados a bases de informações geográficas, litoestratigráficas e de geologia estrutural para o mapeamento de zonas de alteração hidrotermal. Essas bases incluem informações de geologia, geofísica, geoquímica, geomorfologia, lineamentos geológicos, mineralogia e de solos que podem ter sido obtidas em campo, ou não.

2.4 DISCUSSÃO

Os cinco termos ou palavras mais frequentes mapeados pelo VosViewer (Anexo 1) foram: “remote sensing” (166 ocorrências), “iron deposits” (125), “iron ore”(116) “iron oxides” (99) e “mineral exploration” (88). É importante salientar que esse estudo tem como foco verificar o uso de sensoriamento remoto na pesquisa de ferro, portanto, devem ser consideradas as publicações tanto de âmbito científico quanto os de interesse econômico. Desta forma, a utilização de termos restritos a pesquisa mineral como “ore” ou “exploration” poderiam excluir uma parcela dos artigos.

Foi observado uma tendência ascendente do número de artigos publicados ao longo dos anos. Em geral, o gráfico de publicações (Figura 4) se comportou de forma condizente ao panorama do tema, destacando a eficiência no mapeamento de zonas mineralizadas e o desenvolvimento / amadurecimento do sensoriamento remoto como uma ciência. O número crescente de publicações também revela a expansão gradual da disponibilidade dos sistemas de sensores, uma vez que o acesso ao acervo de imagens de satélite não era disponibilizado de forma gratuita até 2007 (Masek et al, 2020). Desta forma, fica evidente que o aumento de publicações está relacionado com a disponibilidade de dados, com o frequente avanço na tecnologia e com o surgimento de novos sensores e técnicas.

Outro ponto importante é considerar que as variações mais acentuadas do número de publicações em anos particulares são decorrentes da área da pesquisa mineral estar diretamente associada a economia mundial. A taxa de consumo de bens minerais, principalmente na indústria e na construção civil, afeta a demanda e o preço das *commodities* de bens minerais e, consequentemente, pode influenciar na rentabilidade do investimento na área (Marziyeh e Osanloo, 2015). Os picos do número de publicações podem estar associados a uma possível alta do preço do minério de ferro, enquanto os anos em que houve uma queda expressiva de publicações, como nos anos de 2009 e 2020, que coincidem com os períodos de mudanças econômicas globais (Song *et al*, 2019; Jowitt, 2020).

Segundo Wårell (2014), o mercado do minério de ferro era caracterizado pelo *Producer Pricing*, ou seja, os maiores produtores (Vale, Rio Tinto e BHP Billiton) e a Indústria europeia do aço tinham total domínio sobre a negociação dos preços, que eram definidos anualmente. Entretanto, após a crise econômica de 2008, esse modelo se tornou insustentável devido as pressões econômicas provenientes das repercussões dessa crise (Silva, 2014).

Ainda segundo Wårell (2014), isso mudou a partir de 2009 quando o mercado global adotou o regime de preços chamado “spot price”, que introduziu um sistema de negociação trimestral, baseado nos preços da commodity no trimestre anterior. Adicionalmente, o mercado do ferro passou a ser dominado pela China que, por conta do seu crescimento acelerado na primeira década do século, impulsionou a demanda global pelo metal, mudando a estrutura de oferta e por consequência os preços, que passaram a incluir os custos de frete no valor final.

Consequentemente, essa mudança de regime teve um efeito significativo nos preços do minério (Figura 11), que aumentaram bruscamente, causando uma verdadeira corrida pela busca de jazidas ferríferas por todo o mundo, que influenciou no aumento de publicações científicas nesse período. Em 2020, com a pandemia do COVID-19, os governos recorreram a investimentos em infraestrutura, com o objetivo de impulsionar o crescimento econômico, o que causou altas históricas do preço do minério (Figura 12).

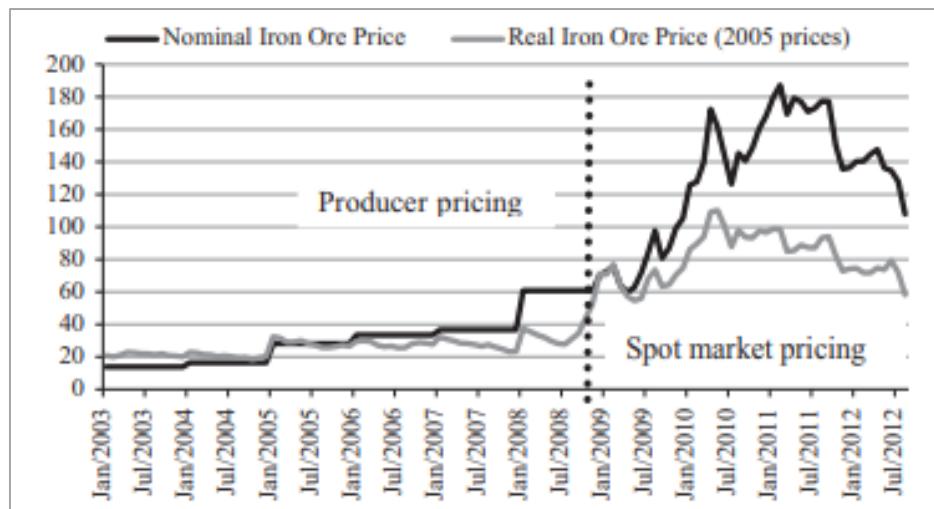


Figura 11 – Preços do minério de ferro de 2003 a 2012 (em dólares americanos por unidade de tonelada métrica seca) (Fonte: Wårell, 2018).

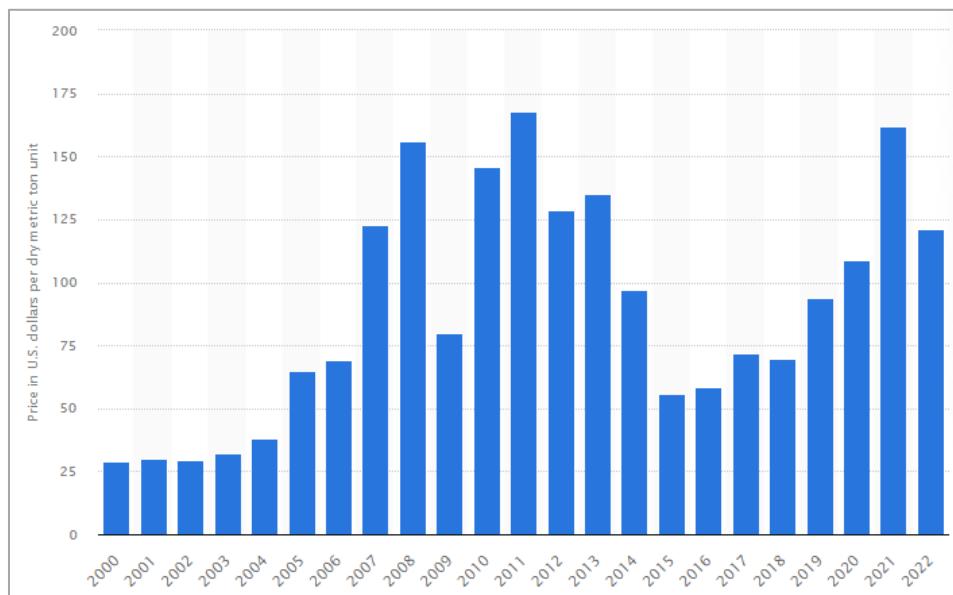


Figura 12 – Preços do minério de ferro de 2000 a 2022 (em dólares americanos por unidade de tonelada métrica seca) (Fonte: Reuters, 2022)

A maioria das publicações está associada com a ocorrência de reservas de minério de ferro e sua contribuição na produção mundial e a nacionalidade de seus autores. Austrália, Brasil, China e Índia, que ficaram entre os cinco países que mais publicaram sobre o tema, são, em respectiva ordem, os líderes da produção de minério de ferro do mundo (Brasil, 2020). O Iran, que foi o país terceiro colocado em número de publicações, é o décimo primeiro maior produtor de ferro do mundo, embora grande parte de suas publicações selecionadas foram voltadas para a pesquisa de depósitos do tipo pôrfiro mineralizados em cobre, onde o ferro aparece

como mineral de associação, por ser um elemento compatível do ponto de vista geoquímico (Majid *et al*, 2018). A Rússia, quinto maior produtor mundial de minério de ferro, teve um número de publicações bem inferior aos demais. Isso é explicado pelo fato que de, nesse país, a produção de ferro não é tão expressiva quando comparado a outras substâncias, sendo o ferro correspondente a 4% da produção mineral (Safirova, 2018).

A relação de autores mais citados e que mais publicaram sobre o tema não é totalmente convergente com o ranking de produção mineral correspondente ao seu país de origem, ou seja, os autores que mais publicaram não são necessariamente dos países que mais produzem minério de ferro. O número de publicações dos autores que focam especificamente na pesquisa mineral em ferro (tabela 2), é relativamente baixo, quando comparado com o número de publicações das instituições (tabela 3). Os mapas da rede da evolução temporal da participação dos países de origem dos artigos publicados e de co-autoria (Figuras 6 e 7) relacionam a citação das publicações de acordo com a localidade do depósito estudado e empresas mineradoras envolvidas, a exemplo dos depósitos de ferro da Província mineral de Carajás, no Brasil, onde temos uma colaboração técnico-científica com artigos de co-autoria entre autores brasileiros do meio acadêmico (Silva, A.M.) e australianos, que trabalham nas mineradoras (Mol, A.G.). Em geral, há uma regionalização das redes de co-autoria dos artigos publicados, com pouca interação interpáises.

No que se refere aos termos mais frequentes e as metodologias mais adotadas para o estudo de áreas potencialmente mineralizadas em ferro, observou-se uma padronização pelo tipo de modelagem geológica exploratória. Os modelos exploratórios envolvem a construção intelectual dos estudos descritivos, conceituais e diagnósticos para integrar as áreas de conhecimento científico com o objetivo de predizer condições geológicas favoráveis à ocorrência de depósitos minerais (Adams, 1985). As linhas de aplicação do sensoriamento remoto, encontrados nas publicações, para esse tipo de modelo foram: mapeamentos litológicos, estruturais e de alteração hidrotermal.

O uso de sensoriamento remoto para mapeamentos litológicos está entre os trabalhos de maior representatividade como uma das técnicas mais tradicionais na

caracterização espectral de regiões mais enriquecidas em óxidos de ferro (Kuzvar e Böhmer, 1986). Sua aplicabilidade é justificada na eficiência do mapeamento de semi-detalhe, como informação complementar aos mapas geológicos de escala regional. Dentre os métodos de processamento digital de imagens mais usuais, temos a composição falsa cor (*false color composite*), razão de bandas (*band ratios*), PCA (*Principal Component Analysis*), MNF (*Minimum Noise Fraction*), LS-Fit (*Least Squares Fitting*) e SAM (*Spectral Angle Mapper*), aplicados em imagens dos sensores Landsat e Aster (Feizi e Mansouri, 2013; Ciampalini, 2016; Shirazi *et al*, 2018; Ourhzif *et al*, 2019), bem como Sentinel (Van der Meer, 2015; Van der Werff, 2020) e Hyperion (Silva, 2016).

O mapeamento de lineamentos é utilizado em conjunto com os estudos litológicos, especialmente para os depósitos de ferro que possuem forte controle estrutural por conta do seu ambiente geotectônico (Gross, 1980). O estudo mais relevante envolvendo os temas dessa análise, na base de dados da *Scopus*, foi proposto por Ahmadi e Pekkan (2021), que realizou uma revisão, no período de 1975-2021, das técnicas de extração de lineamentos de forma manual, semi-automática e automática. Os autores sugerem que a integração de métodos automáticos e manuais, com a utilização de dados de radar, mais especificamente o InSAR (*Interferometric Synthetic Aperture Radar*) e de dados geofísicos, se possível, são bem eficientes para melhor identificação das relações estratigráficas entre as unidades e o mecanismo de alojamento das intrusões e sua interação com as encaixantes.

Os mapeamentos de alteração hidrotermal representam grande valor na pesquisa mineral como recursos na detecção de novas jazidas. No que se refere a depósitos de ferro, como foi observado nas publicações selecionadas nesse estudo, o foco foi no estudo de depósitos do tipo IOCG (*iron oxides-copper-gold*) e as ocorrências lateríticas supergênicas (Teixeira *et al*, 2015). Dentre os métodos de processamento digital de imagens mais usuais, temos a composição falsa cor, razão de bandas, SAM e PCA aplicados em imagens do sensor Landsat (Amos e Greenbaum, 1989), com integração de dados de geofísica e geoquímica. Destaca-se também, a aplicação da espectrometria, aplicados em imagens dos sensores

hiperespectrais (Bedini, 2017) para estimar a relação dos óxidos de ferro e minerais de alteração de acordo com seu comportamento espectral.

A aprendizagem de máquina (*Machine Learning*) e aprendizagem profunda (*Deep Learning*) ainda são temas bastante desafiadores na classificação e reconhecimento de corpos geológicos a partir de imagens de sensoriamento remoto.

Estudos envolvendo inteligência artificial (IA), particularmente o aprendizado de máquina, oferecem oportunidades economicamente benéficas na área das geociências e exploração mineral (Chen and Wu, 2016; Caté et al, 2017; Brandmeier et al, 2019). Essas técnicas recentemente desenvolvidas à prospecção analisam os ativos de informações de alto volume, alta velocidade e / ou alta variedade, conhecidos como *Big Data* (Gartner, 2001), e permitem identificar padrões em grandes conjuntos de dados multivariados e fazer previsões com base neles. Esses métodos têm grande potencial para integração de dados e podem ajudar na tomada de decisões para modelagem de depósitos minerais (Hill et al., 2014).

Sobre essas pesquisas, destacaram-se os pesquisadores chineses que desenvolveram estudos ao treinar uma grande quantidade de dados, para obter automaticamente informações de estruturas geológicas em campo (Zhang et al, 2018). Outros autores, como Liu et al (2021), utilizaram imagens de sensores hiperespectrais com dados geoquímicos e métodos de aprendizado de máquina para elaboração de um modelo geométrico de depósitos hidrotermais do tipo IOCG, com o objetivo de uma fazer uma análise e julgamento relevantes no planejamento de mina, ao melhorar a capacidade de processamento de imagens de sensoriamento remoto de alta resolução, aumentando assim o seu valor de aplicação. Outros trabalhos como o de Harvey e Fotopoulos (2016) utilizaram dados geofísicos, especificamente dados magnéticos de intensidade total, elevação digital do terreno, e anomalia de gravidade Bouguer, para delinear regiões de interesse, como possíveis contatos entre unidades rochosas e tendências estruturais existentes, que são frequentemente escondidos sob material de superfície, a exemplo da vegetação e do solo, inferidos através do algoritmo *random forest*. Um dos trabalhos mais recentes, realizou uma investigação sobre aplicação da aprendizagem profunda na exploração mineral conduzida por Hojat et al (2021), concluiu que a aprendizagem profunda tem boas aplicações para classificação da imagem de acordo com normalização dos espectros de reflectância

para que se possa comparar características de absorção individuais a partir de uma linha de base comum.

2.5 CONCLUSÕES

Este estudo conclui-se reforçando a ideia de que o bibliometria se constitui como uma ferramenta relevante para os estudos da pesquisa mineral, sobretudo para permitir uma contextualização de sua evolução como ciência.

Essa constatação é importante para delimitar os principais eixos temáticos que discutem a utilização do sensoriamento remoto no estudo da exploração para ferro. A análise das redes de palavras-chave permitiu identificar tendências existentes, padrões relacionais e, sendo assim, foi um dado relevante para o prosseguimento desta pesquisa, sobretudo na delimitação do universo de análise que esse trabalho seguirá.

Sobre estas pesquisas, a revisão bibliométrica não indica claramente um procedimento padrão para a modelagem de um depósito mineral, assim, é importante considerar os pontos fortes e as limitações de cada método, em comparação com outros e para além disso, a análise das litologias e dos fatores controladores de uma jazida são fundamentais para a definição dos processos envolvidos na formação de depósitos minerais. A utilização de métodos híbridos, embora complexa e ainda limitada na literatura revisada, parecem promissores na melhor investigação desse campo de atuação.

Para além disso, a continuidade do compartilhamento do conhecimento científico entre países, organizações e autores, que é a melhor estratégia para impulsionar o desenvolvimento da tecnologia, técnicas de cartografia, processamento digital e refinamento das metodologias aplicadas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMS, S.S., 1985. **Using Geological Information to Develop Exploration Strategies for Epithermal Deposits**, Geology and Geochemistry of Epithermal Systems, B. R. Berger, P. M. Bethke. Society of Economic Geologists. V.2, DOI: <https://doi.org/10.5382/Rev.02>.
- AMOS B. J.; GREENBAUM D. ,1989. **Alteration detection using TM imagery The effects of supergene weathering in an arid climate**, International Journal of Remote Sensing, 10:3, 515-527, DOI: 10.1080/01431168908903889
- AHMADI, H.; PEKKAN, E., 2021. **Fault-Based Geological Lineaments Extraction Using Remote Sensing and GIS-A Review**. Geosciences.11. 183. 10.3390/geosciences11050183.
- BEDINI, E., 2022. **The use of hyperspectral remote sensing for mineral exploration: a review**. Journal of Hyperspectral Remote Sensing, [S.I.], v. 7, n. 4, p. 189-211, dec. 2017. ISSN 2237-2202.
- BONHAM-CARTER, G. F. **Geographic information systems for geoscientists**. Modeling with GIS, pp.398, Pergamon, United Kingdoms. 1994.
- BRANDMEIER, MELANIE & CHEN, Y. 2019. **LITHOLOGICAL CLASSIFICATION USING MULTI-SENSOR DATA AND CONVOLUTIONAL NEURAL NETWORKS**. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLII-2/W16. 55-59. 10.5194 / isprs - archives - XLII-2-W16-55-2019.
- BRASIL, Secretaria de Geologia, Mineração e Transformação Mineral (DTTM), Ministério de Minas e Energia (MME). **Boletim do Setor Mineral – Abril de 2020**. 3º Edição, Brasília, 2020, 32p.
- CATÉ, ANTOINE & PEROZZI, LORENZO & GLOAGUEN, ERWAN & BLOUIN, MARTIN. 2017. **Machine learning as a tool for geologists**. The Leading Edge. 36. 215-219. 10.1190/tle36030215.1.
- CHEN, Y. & WU, W. **Mapping mineral prospectivity using an extreme learning machine regression**. 2016. Ore Geology Reviews. 80. 10.1016/j.oregeorev.2016.06.033.
- CIAMPALINI, A.; GARFAGNOLI, F.; ANTONIELLI, B.; MORETTI, S.; RIGHINI, G., 2013. **Remote sensing techniques using Landsat ETM+ applied to the detection of iron ore deposits in Western Africa**. Arabian Journal of Geosciences. 10.1007/s12517-012-0725-0.
- COULTER, D.; ZHOU, X.; WICKERT, L.M; HARRIS, P.D., 2017. **Advances in Spectral Geology and Remote Sensing: 2008 – 2017**. In “Proceedings of Exploration 17: Sixth Decennial International Conference on Mineral Exploration” Toronto, ON, Canada.
- DALTON DE SOUZA, J.; FERNANDES, F. J.; GUIMARÃES, J. T.; LOPES, J. N. 1979. **Projeto Colomi; geologia da região do Médio São Francisco**, Salvador, CPRM. convênio DNPM/CPRM. 3v.

DEB, M.; KAUR, G., 2008. **Earth processes and resources: Metallogeny**. In book: Earth processes and resources: Metallogeny. pp.1-49

ELSEVIER. — **How Scopus Works—Scopus**—Elsevier Solutions. Available online: <<https://www.elsevier.com/solutions/scopus/how-scopus-works/content>>. Acesso em 29 out. 2020.

FEIZI, F.; MANSOURI, E., 2013. **Introducing the Iron Potential Zones Using Remote Sensing Studies in South of Qom Province, Iran**, Open Journal of Geology, Vol. 3 No. 4, 2013, pp. 278-286. doi: 10.4236/ojg.2013.34032.

GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D., & MOORE, R. 2017. **Google Earth Engine: Planetary-scale geospatial analysis for everyone**. *Remote Sensing of Environment*.

GROSS, G. A. **A classification of iron formations based on depositional environments**. Canadian Mineralogist, Ottawa, v. 18, n. 2, p. 215-222, May 1980.

GUSENBAUER, M. 2019. **Google Scholar to overshadow them all? Comparing the sizes of 12 academic search engines and bibliographic databases**. *Scientometrics* 118, 177–214 (2019). <https://doi.org/10.1007/s11192-018-2958-5>

HARVEY, A. & FOTOPOULOS, G., 2016. **Geological mapping using Machine Learning algorithms**. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLI-B8. 423-430. 10.5194/isprs-archives-XLI-B8-423-2016.

HILL, E. J., N. H. OLIVER, L. FISHER, J. S. CLEVERLEY, AND M. J. NUGUS, 2014, **Using geochemical proxies to model nuggety gold depos-its: An example from Sunrise Dam, Western Australia**: *Journal of Geochemical Exploration*, 145, 12–24.

HO, T. K. 1995. **Random Decision Forests**. Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, QC, 14–16 August 1995. pp. 278–282.

HOJAT, S.; EHSAN, F.; DIETMAR, M.R.; ROHITASH, C., 2021. **A review of machine learning in processing remote data for mineral exploration**. *Remote Sensing of Environment*. Open Access. Volume 268January 2022 Article number 112750

HUNT, G.R.; SALISBURY, J.W.; LENHOFF, C.J. **Visible and Near-infrared Spectra of Minerals and Rocks: III. Oxides and Hidroxides**. *Modern Geology*, 1971, 2, pp. 195- 205.

JOWITT, S.M., 2020. **COVID-19 and the Global Mining Industry**. *SEG Discovery* 2020; (122): 33–41. doi: <https://doi.org/10.5382/SEGnews.2020-122fea-02>

KUZVART, M. & BÖHMER, M. 1986. **Prospecting and exploration of mineral deposits**. 2a. ed., *Developments in economic geology* vol. 21, Elsevier Ed., (N.Y.) USA, 508 pp

LIU, L.; CHEN, J.; ZHOU, T.; ZAHNG, Y.; LI, M., 2021. **The new application of geometallurgy in deportment of gold and critical metals studies**. *Yanshi Xuebao/Acta Petrologica Sinica*, Volume 37, Issue 9, Pages 2691 – 2704.

LOBO, F.L; SOUZA-FILHO, P.W.M; NOVO, E.M.L.M; CARLOS, F.M; BARBOSA, C.C.F. **Mapping mining areas in the Brazilian amazon using M SI/ Sentinel-2 Imagery (2017).** Remote Sens. 2018, 10 (8), 1178.

MAJID, G; NARGES, Y.; KONARI, B.M., 2018. **Porphyry Copper Deposits of Iran.** Publisher: Tarbiat Modares University. Dec 2018, ISBN: 978.600.7589.69.4

MARZIYEH, M.M.; OSANLOO, M., 2015. **Chaos in iron ore price prediction.** Conference: The Southern African Institute of Mining and Metallurgy MPES 2015 – Smart Innovation in MiningAt: Sandton Convention Centre, Johannesburg, South Africa.

MASEK, J.G; WULDER, M.A.; MARKHAM, B.; MCCORKEL, J.; CRAWFORD, C.J.; STOREY, J.; JENSTROM, D.T., 2020. **Landsat 9: Empowering open science and applications through continuity.** Remote Sensing of Environment, V. 248, 111968, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2020.111968>.

MENESES, P.R; ALMEIDA, T. 2012. **Introdução ao processamento de imagens de sensoriamento remoto.** UNB. Brasília, DF. 276p.

OURHZIF, Z.; AHMED, A.; AB, A.; FATIHA, H., 2019. **Lithological mapping using landsat 8 oli and aster multispectral data in imini-ounilla district south high atlas of marrakech.** ISPRS Journal of Photogrammetry and Remote Sensing. XLII. 1255-1262. 10.5194/isprs-archives-XLII-2-W13-1255-2019.

RAJESH, H.M., 2004, **Application of remote sensing and GIS in mineral resource mapping: an overview.** Queensland, Australia. Journal of Mineralogical and Petrological Sciences, v. 99, pp 83-103 Jun/2004.

SAFIROVA, H., 2018. **The Mineral Industry of Russia.** USGS Minerals Yearbook. Advance Release, Chapter 19, p.19.

SAIBI, HAKIM & BERSI, MOHAND & MIA, MD & SAADI, NUREDDIN & AL BLOUSHI, KHALID & AVAKIAN, ROBERT. 2018. **Applications of Remote Sensing in Geoscience.** 10.5772/intechopen.75995.

SANTANA, M.; MARIANO-NETO, E.; VASCONCELOS, R.; DODONOV, P.; MEDEIROS, J. 2021. **Mapping the research history, collaborations and trends of remote sensing in fire ecology.** Scientometrics. 126. 10.1007/s11192-020-03805-x.

SILVA, A.; DUCART, D.; TOLEDO, B.; ASSIS, L., 2016. **Mapping iron oxides with Landsat-8/OLI and EO-1/Hyperion imagery from the Serra Norte iron deposits in the Carajás Mineral Province, Brazil.** Brazilian Journal of Geology. 46. 331-349. 10.1590/2317-4889201620160023

SILVA, A.B. **Sistemas de Informações Geo-referenciadas: Conceitos e fundamentos.** Livro texto, 1^a Ed 2003, UNICAMP, Campinas, SP, 236p.

SILVA, E. M.; **O Mercado mundial de Minério de Ferro e seus efeitos sobre a balança Comercial Brasileira.** Monografia, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro. 2014.

SONG, Y.; WANG, N.; YU, A., 2019. **Temporal and spatial evolution of global iron ore supply-demand and trade structure**. Resources Policy, V.64, 101506, ISSN 0301-4207, <https://doi.org/10.1016/j.resourpol.2019.101506>.

SHIRAZI, A.; HEZARKHANI, A.; SHIRAZY, A., 2018. **Remote Sensing Studies for Mapping of Iron Oxide Regions, South of Kerman, IRAN**. International Journal of Science and Engineering Applications. 7. 045-051. 10.7753/IJSEA0704.1002.

SOARES FILHO, A. 2015. **Análise de processos de transformação da paisagem com base em espectroscopia de reflectância e sensoriamento remoto multiespectral: Estudo de caso no núcleo de Gilbués, Piauí, Brasil**. Tese de Doutorado, UNICAMP, Campinas, SP, 161p.

SOUZA, J. D. de et al. **Projeto Colomi: relatório final: geologia e prospecção geoquímica da região de Remanso-Sento Sé**. Salvador: CPRM, 1979. 10 v.

SOUZA FILHO, C.R.; TAPIA CALLE, C.H.; CROSTA, A.P.; XAVIER, R.P. **Infrared Spectroscopy and ASTER imagery Analysis of Hidrothermal alteration Zones at the Quellaveco Porphyry-Copper deposit, Southern Peru**. In: Ann. Conf. of Am. Soc. for Photog. and Rem. Sens. (ASPRS), Proceedings, 2003, pp. 1-12.

TEIXEIRA, N.; GANADE, C.; MATOS, F.; CAMPOS, L.; NAVES, M.C., 2015. **Alkaline porphyry copper deposits and iocg – what is the link**.

VAN DER MEER, F.D.; VAN DER WERFF, H.M.A. **Sentinel-2 for Mapping Iron Absorption Feature Parameters**. Remote Sensing of Environment, 2015, 7, 12635–12653.

VAN DER WERFF, H., HEWSON, R. **Using Sentinel-2 MSI for mapping iron oxide minerals on a continental and global scale**. Authorea. January 15, 2020.

VASCONCELOS, R.N.; LIMA, A.T.C.; LENTINI, C.A.D.; MIRANDA, G.V.; MENDONÇA, L.F.; SILVA, M.A.; CAMBUÍ, E.C.B.; LOPES, J.M.; PORSANI, M.J., 2020. **Oil Spill Detection and Mapping: A 50-Year Bibliometric Analysis**. Remote Sens. 2020, 12, 3647. <https://doi.org/10.3390/rs1221364>

WÅRELL, L. **The effect of a change in pricing regime on iron ore prices**. Resources Policy, 41, 16-22. 2014.

WÅRELL, L. **An analysis of iron ore prices during the latest commodity boom**. Mineral Economics, <https://doi.org/10.1007/s13563-018-0150-2>. 2018.

WU, C.; LI, X.; CHEN, W.; LI, X., 2018. **A Review of Geological Applications of High-Spatial-Resolution Remote Sensing Data**. 10.20944/preprints201811.0162.v1.

YE, Z.; WANG, G.; LI, M.; HAN, S., 2018. **Automated Classification Analysis of Geological Structures Based on Images Data and Deep Learning Model**. Applied Sciences. 8. 2493. [10.3390/app8122493](https://doi.org/10.3390/app8122493).

ZHANG, Y.; GANG, W.; MINGCHAO, L.; SHUAI, H., 2018. **Automated Classification Analysis of Geological Structures Based on Images Data and Deep Learning Model**. Applied Sciences. 8. 2493. [10.3390/app8122493](https://doi.org/10.3390/app8122493).

ANEXO 1 – 50 TERMOS MAIS FREQUENTES MAPEADOS PELO VOSVIEWER

Colocação	termo	Número de ocorrências
1	Remote sensing	166
2	Iron deposits	126
3	Iron ore	116
4	Iron Oxides	99
5	Mineral exploration	88
6	mapping	87
7	minerals	87
8	Satellite imagery	85
9	Spectral analysis	76
10	Hydrothermal alteration	72
11	landsat	72
12	Geological mapping	70
13	hematite	65
14	reflection	62
15	lithology	57
16	Spectral reflectance	55
17	Image processing	55
18	geochemistry	53
19	multiespectral	50
20	Alteration zones	49
21	Infrared spectroscopy	42
22	Detection method	40
23	Reflectance spectrum	38
24	algorithm	36
25	Spatial distribution	34

26	absorption	33
27	Natural resources	29
28	stratigraphy	15
29	radiology	12
30	Image resolution	11
31	hyperspectral	9
32	Band ratio	8
33	Regression analysis	6
34	magnetite	6
35	Learning systems	5
36	Artificial intelligence	5
37	Banded iron formation	5
38	wavelenght	5
39	indicator	4
40	Ferric oxide	4
41	lineament	4
42	pca	4
43	correlation	4
44	soil	3
45	Gold deposits	3
46	weathering	3
47	Rare earths	3
48	porphyry	3
49	kaolinite	2
50	mica	2



Capítulo III

APLICAÇÕES DE SENSORIAMENTO REMOTO NO MAPEAMENTO PROSPECTIVO PARA FERRO: POTENCIALIDADE NO ESTADO DA BAHIA.

3.1 INTRODUÇÃO

O estado da Bahia conta com uma ampla diversidade geológica e potencial metalogenético. Além de possuir rochas dentre as mais antigas da Terra, com idades estimadas a 3,4-3,5 bilhões de anos, seu histórico de atividades tectônicas e geomorfológicas contribuíram para a geração de um grande e diversificado acervo litológico (Carvalho *et al*, 2010). Esse panorama geodinâmico favoreceu inúmeros processos mineralizantes em seu território (Teixeira *et al*, 2010), resultando na formação de províncias minerais, fato que posicionou a Bahia entre os cinco estados com maior disponibilidade de recursos minerais do Brasil.

Nesse sentido, a Bahia ocupa um papel de destaque no cenário da mineração do Brasil como o terceiro maior produtor mineral do país (SDE, 2022), com ênfase na produção de ouro, cobre e níquel, que representam 65% de toda produção mineral do estado. Além disso, temos o vanádio e cromo, substâncias que a Bahia lidera como maior produtor nacional, por possuir as maiores reservas minerais do país.

Para o minério de ferro, a produção na Bahia representa, aproximadamente, 6% dos principais bens minerais produzidos no estado (SDE, 2022), mesmo com ocorrências de depósitos ferríferos de médio a grande porte distribuídos por todo seu território (Figura 1). Os Distritos do Sudoeste (Caetité/Brumado) e do Norte da Bahia (Remanso/Sento Sé) destacam-se pela quantidade e qualidade dos seus recursos,

com tonelagens totais estimadas acima dos 10 bilhões de toneladas. Ambos contêm minérios com concentrações de Fe que variam entre 35% e 45% em média, com ocorrência de teores entre 50% e 67%, nos depósitos de Caetité/Brumado (Lanfranchi et al., 2017) e de Remanso/Sento Sé (Ribeiro, 2017). Unidades hematíticas e itabiríticas espessas ligadas a sequências sedimentares vulcânicas estão relacionadas com estes depósitos (Alves, 2008; Cunha et al, 2008). No Recôncavo Baiano, encontram-se também minérios de baixo grau (>30% Fe), associados a anfibolitos, compactos a semi-compactos, principalmente nos depósitos de Coração de Maria. Além das informações citadas, são escassas as produções acadêmicas sobre a pesquisa de minério de ferro no estado e os poucos registros encontrados são da literatura técnica em campanhas pontuais (Leonardos, 1937; Santana et al., 1974; Souza et al., 1979, Alves, 2008; Cunha et al, 2008, Lanfranchi et al., 2017; Ribeiro, 2017). Adicionalmente, a maior parte das informações essenciais como a localização e a caracterização quantitativa / qualitativa dos depósitos estão limitados às mineradoras que os detêm por questões estratégicas e sigilo industrial. Entretanto, ao todo, estima-se que existem pelo menos 12,5 bilhões de toneladas de ferro ainda não explorados distribuídos em pelo menos cinco distritos ferríferos no estado (Ribeiro, 2017).

De acordo com o anuário mineral brasileiro (Brasil, 2022), a produção beneficiada da Bahia em 2021 foi de, aproximadamente, 1,8 milhões de toneladas (0,016% da produção nacional de ferro), com teor de Fe de 65,5%. Comparando com o estado de Minas Gerais, que no mesmo ano, produziu 225,17 milhões de toneladas (64,35%), com teor de 61,92% e o Pará 188,83 milhões de toneladas (34,5%) com teor de 64,93%, o estado ainda está longe de se tornar um importante componente na minério-indústria da produção de ferro do país. Dentre os fatores limitantes para um crescimento expressivo da mineração baiana está na deficiência de uma logística de transporte. Atualmente, a Bahia não possui uma infraestrutura robusta para o escoamento dessa produção (CBPM, 2023). A FCA (Ferrovia Centro-Atlântica), que cruza o estado norte-sul e é o único acesso ferroviário para os Portos de Salvador e de Aratu-Candeias, encontra-se sem manutenção e o trecho 1 da FIOL (Ferrovia de Integração Oeste-Leste), que liga a cidade de Caetité (próxima a Mina Pedra de Ferro) ao Porto Sul, ainda está em construção, com previsão de conclusão em 2026.

Outro fator importante é a necessidade de uma pesquisa capaz de inovar, integrar e caracterizar qualitativamente/quantitativamente o conhecimento técnico-científico a partir dos dados disponibilizados, que possa dar suporte a um projeto logístico de grande escala. Esses são vetores importantes em qualquer fase de planejamento e tomada de decisão. Com um projeto logístico ferro-portuário otimizado e investimentos em sistemas de beneficiamento no estado, indubitavelmente, a Bahia se posicionaria como um dos importantes produtores de minério de ferro do Brasil, juntamente com os estados de Minas Gerais, e Pará, os maiores produtores de ferro do país.

Com base nesse cenário, é preciso um melhor entendimento do panorama mineiro regional para ferro, para direcionar as análises e interpretações metalogenéticas dos depósitos a nível local. Desta forma, o uso de sensoriamento remoto na pesquisa mineral, representa um dos estágios iniciais da exploração (Hronsky e Groves, 2008), ao fornecer mapeamentos de potencial mineral combinando dados geológicos, mineralógicos, geoquímicos, geofísicos, espectrais e propriedades físicas da rocha (Silva, 2016), possibilitando a identificação de áreas de relevante interesse econômico em áreas extensas (Feizi e Mansouri, 2013; Ciampalini, 2016; Shirazi *et al*, 2018; Ourhzif *et al*, 2019), (Van der Meer, 2015). No capítulo anterior, vimos que os modelos exploratórios envolvem a construção intelectual dos estudos descritivos, conceituais e diagnósticos para integrar as áreas de conhecimento científico com o objetivo de predizer condições geológicas favoráveis à ocorrência de depósitos minerais. Esses modelos predizem condições geológicas favoráveis à ocorrência de depósitos minerais em multi-escala, gerando alvos para os levantamentos em detalhe (follow-ups) nos estágios finais da pesquisa mineral (Adams, 1985), (Soares Filho, 2015).

Este trabalho tem como objetivo desenvolver uma metodologia para o mapeamento de áreas potenciais a prospecção de ferro. O estudo visa avaliar o uso de técnicas de processamento digital de imagens e modelagem de dados aplicados aos dados de sensoriamento remoto como subsídios para otimizar os trabalhos de campo contemplados na pesquisa mineral e contribuir com o avanço da pesquisa científica e na construção do conhecimento.

3.2 METODOLOGIA

3.2.1 Área de estudo

O estado da Bahia está localizado na porção mais meridional da região nordeste do Brasil. O contexto geológico regional das formações ferríferas do estado segue, predominantemente, o mesmo padrão da maioria das ocorrências de ferro no mundo, com deposições entre o mesoarqueano e o paleoproterozoico (~3,2 – 1,6 Ga) (Biondi, 2003) ocorrendo, comumente, em três tipos distintos: Lago Superior, Algoma e Rapitan (Gross, 1980). Os ambientes geotectônicos associados a esses tipos de depósitos são, respectivamente, as plataformas de margem continental; cinturões tectônicos de arcos vulcânicos e *riffs* das cadeias meso-oceânicas; e aos vales em *riffs* e *grabens* de terrenos glaciais de alto relevo (Chemale Junior e Takehara, 2013). Na Bahia, a maior parte das ocorrências de ferro conhecidas são do tipo Algoma, associados aos ambientes de *greenstone belts* de idades neoarqueana a paleoproterozóica. Entretanto, as maiores reservas estão relacionadas as sequências metavulcanossedimentares paleoproterozóicas, consideradas do tipo Lago Superior (Santana *et al*, 1974). Esses ambientes são representados pela ocorrência de formações ferríferas bandadas (*Banded Iron Formations* – BIFs): rochas sedimentares formadas por camadas intercaladas de deposições de óxido de ferro e de sílica e/ou carbonatos.

O estado conta com clima, relevo, tipos de vegetação e solo variados (IBGE, 2004). A porção leste está inserida no bioma mata atlântica com clima litorâneo úmido com transição para o clima tropical, com temperaturas sempre superiores a 18Cº e chuvas bem distribuídas durante o ano todo (Pereira, 2009). A vegetação varia com a predominância de formações florestais, com algumas áreas de mangue e de restinga (IBGE, 2012). Essa região é composta em sua maior parte por uma faixa de sedimentos quaternários recobrindo terrenos granulíticos do mesoproterozoico com relevo representado pelos platôs sedimentares bastante ondulados e solos do tipo latossolos e argissolos. A porção oeste do estado é composta predominantemente por coberturas sedimentares do proterozoico e fanerozoico e corresponde ao bioma cerrado, com clima tropical sazonal, com estações chuvosas e períodos de seca bem demarcados e variações de temperatura, mais frias nos períodos secos e mais

quentes nos períodos chuvosos (Sano *et al*, 2008). A vegetação predominante é composta por formações campestres e savânicas (IBGE, 2012), o relevo é mais ou menos aplainado com grande presença de chapadas cortadas por patamares e os solos são do tipo latossolos, neossolos, espodossolos e cambissolos. O restante do estado está inserido no bioma caatinga, característico pelo clima semi-árido, com baixos índices pluviométricos e altas temperaturas (Ab'sáber, 1974). A vegetação é representada pelas formações savânicas estépicas (IBGE, 2012), o relevo apresenta altitudes variadas, com existência de chapadas e planaltos cortados por depressões interplanálticas pediplanizadas, com solos, em geral, rasos e muito arenosos, representados por latossolos, argissolos, neossolos, vertissolos e cambissolos.

3.2.2 Desenho amostral

Geralmente para os métodos de sensoriamento remoto empregados na exploração mineral, é necessário que a área selecionada para modelagem contenha um número satisfatório de dados de entrada que se deseja pesquisar (Bonham-Carter, 1994). Este trabalho propõe avaliar uma aplicação de análise espacial guiada por um conjunto restrito de dados de entrada. Essas amostras servem para treinar e avaliar o modelo através de comparações e cálculos estatísticos aplicados ao conjunto de mapas evidenciais. Para isso, foram escolhidas a Mina Pedra de Ferro, no município de Caetité e a Mina Mocó no município de Piatã, por representarem depósitos de ferro de grande e pequeno porte, respectivamente. A partir da localização central das minas, foram delimitadas zonas de amostras aleatórias de amostras para o treinamento, denominadas estratos amostrais. Foram definidos cinco estratos amostrais a partir da área da cava das minas, seguido por um *buffer* realizado em seu entorno (Tabela 4). Para avaliar a classificação foram selecionadas três zonas de controle: as áreas de concessão de lavra e de requerimento de pesquisa para minério de ferro, extraídas da plataforma Sigmine da Agência Nacional de Mineração (ANM) e a geologia obtida do Serviço Geológico Brasileiro SGB-CPRM (Figura 13).

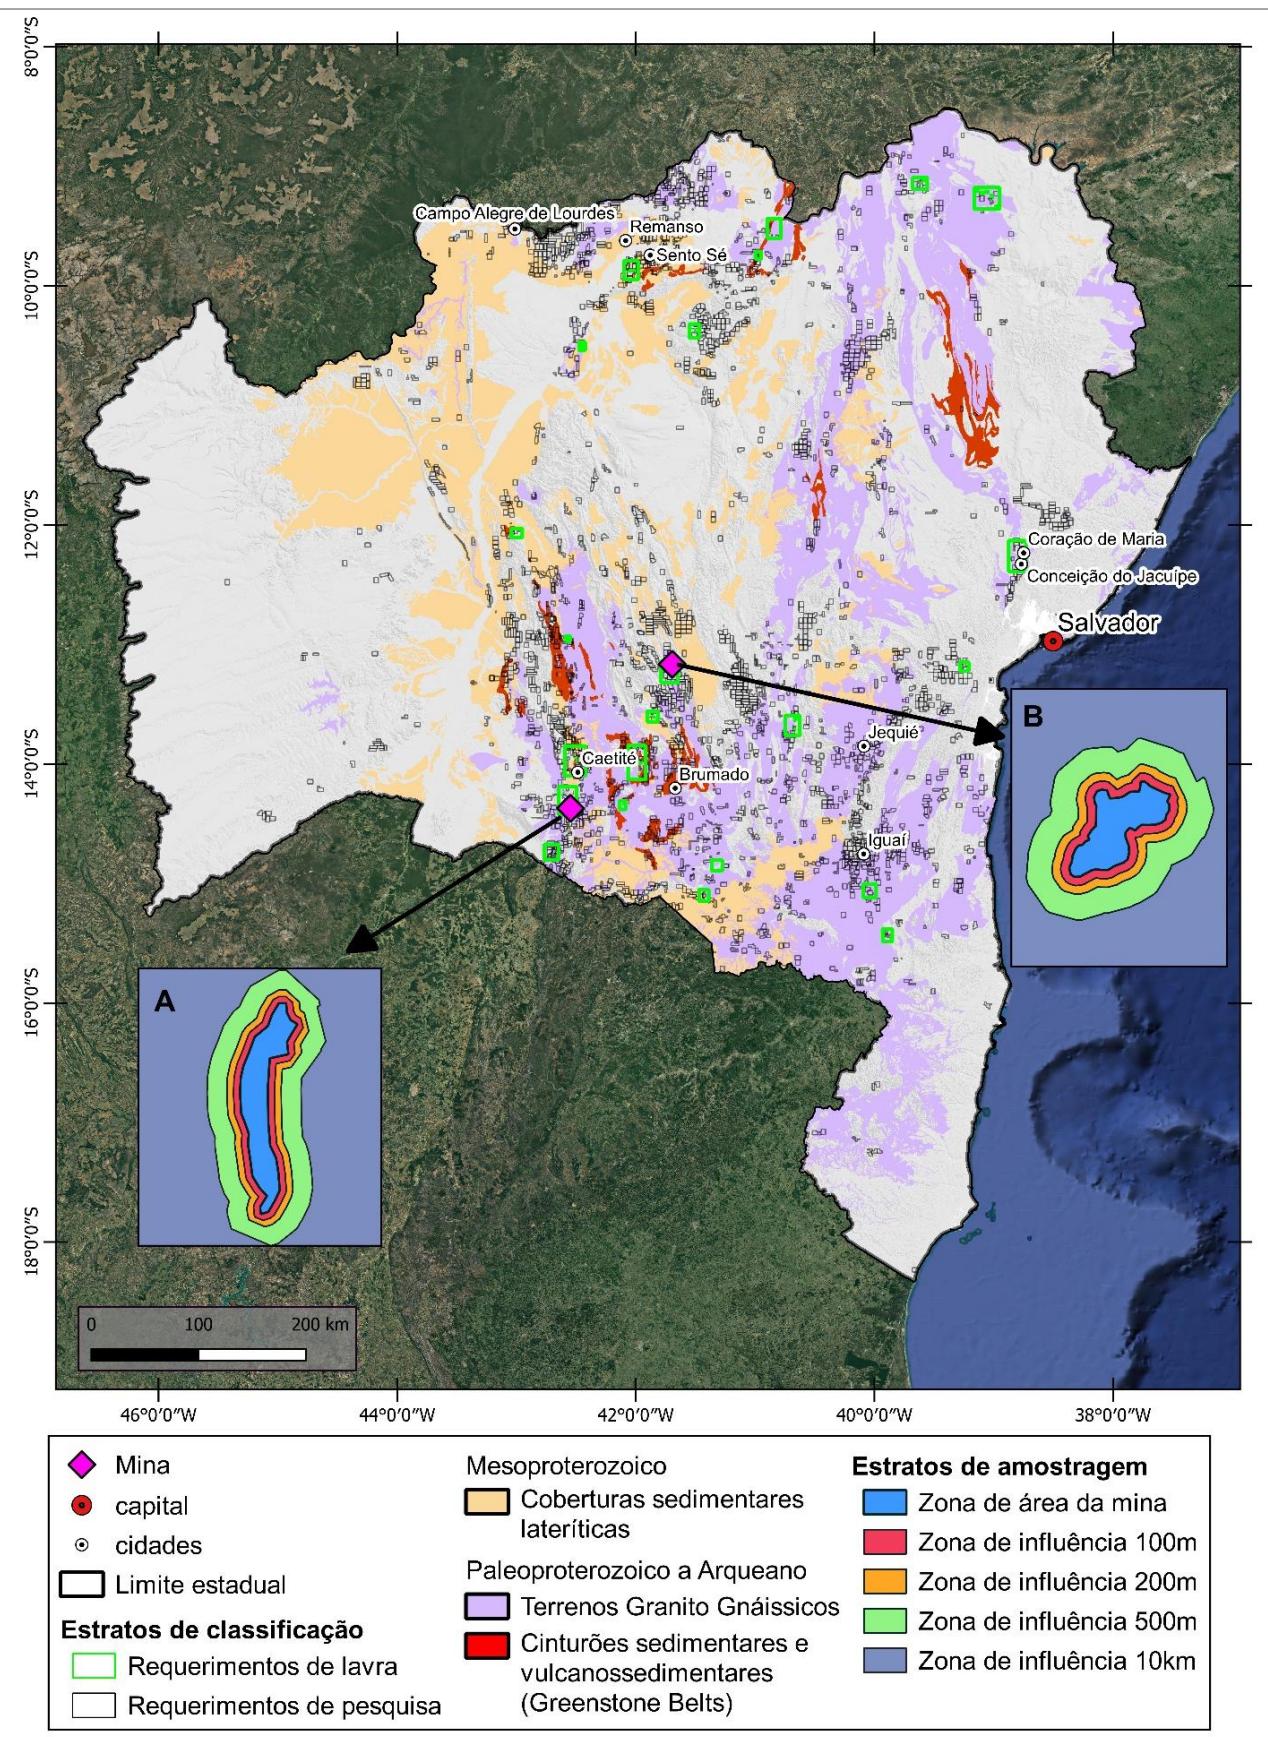


Figura 13 – Mapa de localização da área de estudo sobreposta a imagem SRTM sombreada, destacando os estratos de amostragem na Mina Pedra de ferro (A) e Mina Mocó (B), os estratos de classificação e a geologia simplificada.

Tabela 4 – Tabela da relação dos estratos de amostragem, utilizados para os dados de entrada (input) e os estratos de classificação, utilizados como zonas de controle para a classificação supervisionada.

Categoría	Descrição	Fonte	Nº de amostras
Estrato amostral	Delimitação de área correspondente a cava da mina	autor	20
Estrato amostral	Delimitação da área de entorno da mina, correspondente a zona de influência de 100m	autor	20
Estrato amostral	Delimitação da área de entorno da mina, correspondente a zona de influência de 200m	autor	20
Estrato amostral	Delimitação da área de entorno da mina, correspondente a zona de influência de 500m	autor	20
Estrato amostral	Delimitação da área de entorno da mina, correspondente a zona de influência de 10km	autor	40
Estrato de validação	Poligonais de concessão de lavra requeridas e autorizadas para minério de ferro como substância principal	ANM	
Estrato de validação	Poligonais de pesquisa mineral requeridas e autorizadas para minério de ferro como substância principal	ANM	
Estrato de validação	Unidades litoestratigráficas com favorabilidade de ocorrência de formações ferríferas	CPRM	

3.2.3 Biblioteca espectral e índices

Para esta etapa, usa-se a Espectroscopia de Reflectância, que é uma técnica que mede, em diferentes comprimentos de onda, a energia eletromagnética refletida da superfície dos materiais e representa na forma de um gráfico, denominado de curva de reflectância espectral; que é uma fonte de referência para a interpretação de imagens e funciona como uma assinatura para distintos materiais. (Meneses e Almeida, 2012). A quantidade de radiação refletida (radiância) comparada com a radiação incidente (irradiância) sobre os objetos fornece a medida de reflectância captada por sensores, chamados espectrorradiômetros. Essas medidas espectroradiométricas são úteis na área de geologia de exploração, por auxiliar na determinação da composição mineralógica de uma rocha e, consequentemente, na identificação de mineralizações economicamente relevantes.

O primeiro passo consistiu em construir uma biblioteca espectral de referência. Essa biblioteca é composta por um conjunto de espectros de reflectância de materiais

de composição conhecida, obtidas em campo, na região das minas Pedra de Ferro e Mocó e medidas no laboratório de espectrometria de reflectância (LABESPECTRO) na Universidade Estadual de Feira de Santana (UEFS - Bahia) com um espectrorradiômetro do tipo FieldSpec® 4 Hi-Res, com resolução VNIR de 3 nm e SWIR de 8 nm, com desempenho espectral de irradiação solar de gama completa (350-2500 nm). Foram selecionadas amostras mineralizadas e não mineralizadas em ferro, bem como amostragem de solo da camada superficial nos locais de rocha mineralizada, como uma informação auxiliar para verificar uma possível associação com outras áreas de mineralização similar no mapeamento espectral. Cada amostra foi medida em todas suas faces, fresca e exposta, com atenção nas diferenças na resposta espectral relacionada às variações texturais, especialmente, de micro-relevo, com o objetivo de obter espectros mais padronizados e com menos ruídos. Por fim, cada medição espectral gera como resultado uma tabela com os valores de refletância referentes a cada comprimento de onda. Esses dados foram cedidos por LANFRANCHI et al (2017) de sua tese de doutorado. A partir daí, foram geradas médias das medições de cada amostra, o que possibilitou a construção dos gráficos das assinaturas espetrais por amostra. Esses gráficos foram armazenados no formato de uma biblioteca espectral de referência.

O segundo passo foi construir a biblioteca espectral amostral, a partir das amostras aleatórias coletadas. A comparação com a informação contida na biblioteca espectral de referência possibilita a identificação dos minerais e rochas presentes na imagem (Clark, 1999). Na amostragem por estratos, efetuada no mosaico da imagem de satélite, foram gerados pontos aleatórios em cada estrato amostral. O objetivo dessa etapa foi extrair amostras aleatórias de pixels correspondentes aos diferentes elementos geográficos da imagem. Em seguida, cada ponto foi inspecionado, categorizado e separado em conjuntos de acordo com os estratos de amostragem. Para o minério de ferro exposto, foram selecionados os pixels referentes aos pontos localizados na área da cava das minas. Para o solo, foram selecionados os pontos referentes as áreas de solo exposto sem vegetação. Para mistura de solo e vegetação, as áreas com solo exposto e pouca vegetação e para os pontos de vegetação, foram consideradas as áreas de vegetação sem solo exposto.

Para a escolha do sensor, foi preciso considerar o tipo de substância alvo e a área de estudo proposta. No capítulo anterior, observamos a aplicação de diversas técnicas de modelagem e processamento digital de imagens, com o objetivo de mapear áreas com a existência de minerais que contêm ferro, através da utilização de diferentes sensores como o Landsat e Aster (Feizi e Mansouri, 2013; Ciampalini, 2016; Shirazi *et al*, 2018; Ourhzif *et al*, 2019), bem como Sentinel-2 (Van der Meer, 2015; Van der Werff, 2020) e Hyperion (Silva, 2016). Desta forma, a utilização do Sentinel-2 foi a mais ideal para esse trabalho. O sensor apresenta uma vantagem por possuir múltiplas bandas (5-8) no intervalo de comprimento de onda entre 0,7 e 0,9 µm, região onde é observada características de absorção de minerais ferríferos como goethita (~0,78-0,92µm), jarosita (~0,72-0,93µm) e hematita (~0,75-0,84µm) (Van der Meer, 2015), enquanto outros sensores multiespectrais, como o Landsat e Aster, fornecem apenas uma única banda. Contudo, é considerado inferior quando comparado com sensores hiperespectrais, como o Hyperion, Hymap e o WorldView 3. No entanto, o Sentinel-2 possui alta capacidade de revisita (10 dias) o que possibilita obter uma cobertura espacial completa, mais homogênea e com menos nuvens em toda área de estudo.

3.2.4 Análise de indícios (potencial) de mineralização

A comparação das curvas espectrais obtidas com os dados Sentinel-2 com a biblioteca espectral de referência foi realizada através do método SAM (Spectral Angle Mapper). A técnica SAM permite o mapeamento da similaridade entre o espectro de um píxel da imagem e o espectro de referência de bibliotecas espetrais, seja proveniente de campo, laboratório ou extraído da própria imagem (Kruse *et al.*, 1993). O SAM realiza um cálculo do ângulo entre os espectros amostrados e os de referência para determinar a sua semelhança, através de um algoritmo que converte todos os espectros em vetores em um espaço com o número de dimensões igual ao número de bandas espetrais utilizadas na imagem.

Como resultado, foi obtido o percentual de semelhança de cada espectro das amostras coletadas, com base na sua proximidade com o espectro de referência de cada substância mineral. Para os índices de potencialidade, as amostras foram reclassificadas considerando três fatores: o estrato amostral, o tema referente ao

elemento geográfico superficial na imagem e a média dos percentuais de semelhança das amostras coletadas com a biblioteca de referência. Desta forma, foi possível atribuir uma hierarquia para cada conjunto de amostras, por tema e estrato amostral, de acordo com o percentual de semelhança com a biblioteca de referência (Anexo 2). Essas novas classes foram utilizadas para definir os níveis de potencialidade mineral. Para essa etapa, foi utilizado o software ENVI 5.3, com recortes da imagem Sentinel referentes as zonas de estrato amostral.

Mapas de potencialidade mineral são utilizados para identificar áreas que possuem boas hipóteses de hospedar recursos minerais (Ford, 2013). Envolve uma abordagem estatística multivariada com a extração de evidências espaciais, dado um conjunto de entrada, organizada em SIG (Sistema de Informações Geográficas). Em seguida, uma análise de previsão por ponderação, que pode ser orientada ao dado (*data driven*), a exemplo dos algoritmos de *machine learning* (Ho, 1995; Chen, 2016; Harvey, 2016; Caté, 2017; Brandmeier, 2019; Hojat, 2021), ou orientada ao conhecimento (*knowledge driven*), como a lógica fuzzy (Bonham-Carter, 1994), para combinar, interpretar e avaliar a previsão de áreas importantes a partir de um conjunto de evidências conhecidas.

A detecção de alvos potenciais através da análise de píxel foi um produto de uma classificação através de um algoritmo de *machine learning*. Uma das técnicas de *machine learning* bastante promissoras para a área de prospecção mineral são as de *ensemble learning*, um tipo de aprendizagem supervisionada que combina as previsões de vários estimadores base com múltiplos algoritmos de aprendizado para obter um modelo preditivo mais robusto (Caté et al., 2017). O algoritmo *random forest* é um dos mais utilizados, por ser mais simples a sua implementação e por gerar bons resultados, ao criar uma coleção de árvores de decisão, em que a classificação ou regressão, no caso, é obtida através do voto majoritário da “floresta”, assim, capaz de gerar previsões mais estáveis e com boa acurácia (Ho, 1995).

Na plataforma Google Earth Engine, os seguintes parâmetros-chave foram definidos durante a implementação desta etapa: (1) Seleção das bandas vermelho, red-edge2, NIR, red-edge4 e SWIR1 do mosaico Sentinel-2; (2) conjunto de treinamento composto pelas amostras coletadas, de acordo com as classes de potencialidade. (3) As unidades litoestratigráficas, com contexto geológico favorável

a formação de depósitos minerais ricos em ferro, como limite de extensão da classificação supervisionada. Após a execução do *Random Forest*, foram avaliados o nível de precisão da classificação, com base na matriz de confusão e o nível de importância variável, através da utilização de pontos com ocorrências de ferro, extraídos da base da CPRM, para validação do modelo.

O fluxograma metodológico (Figura 14) ilustra as fases e etapas envolvidas nesse trabalho.

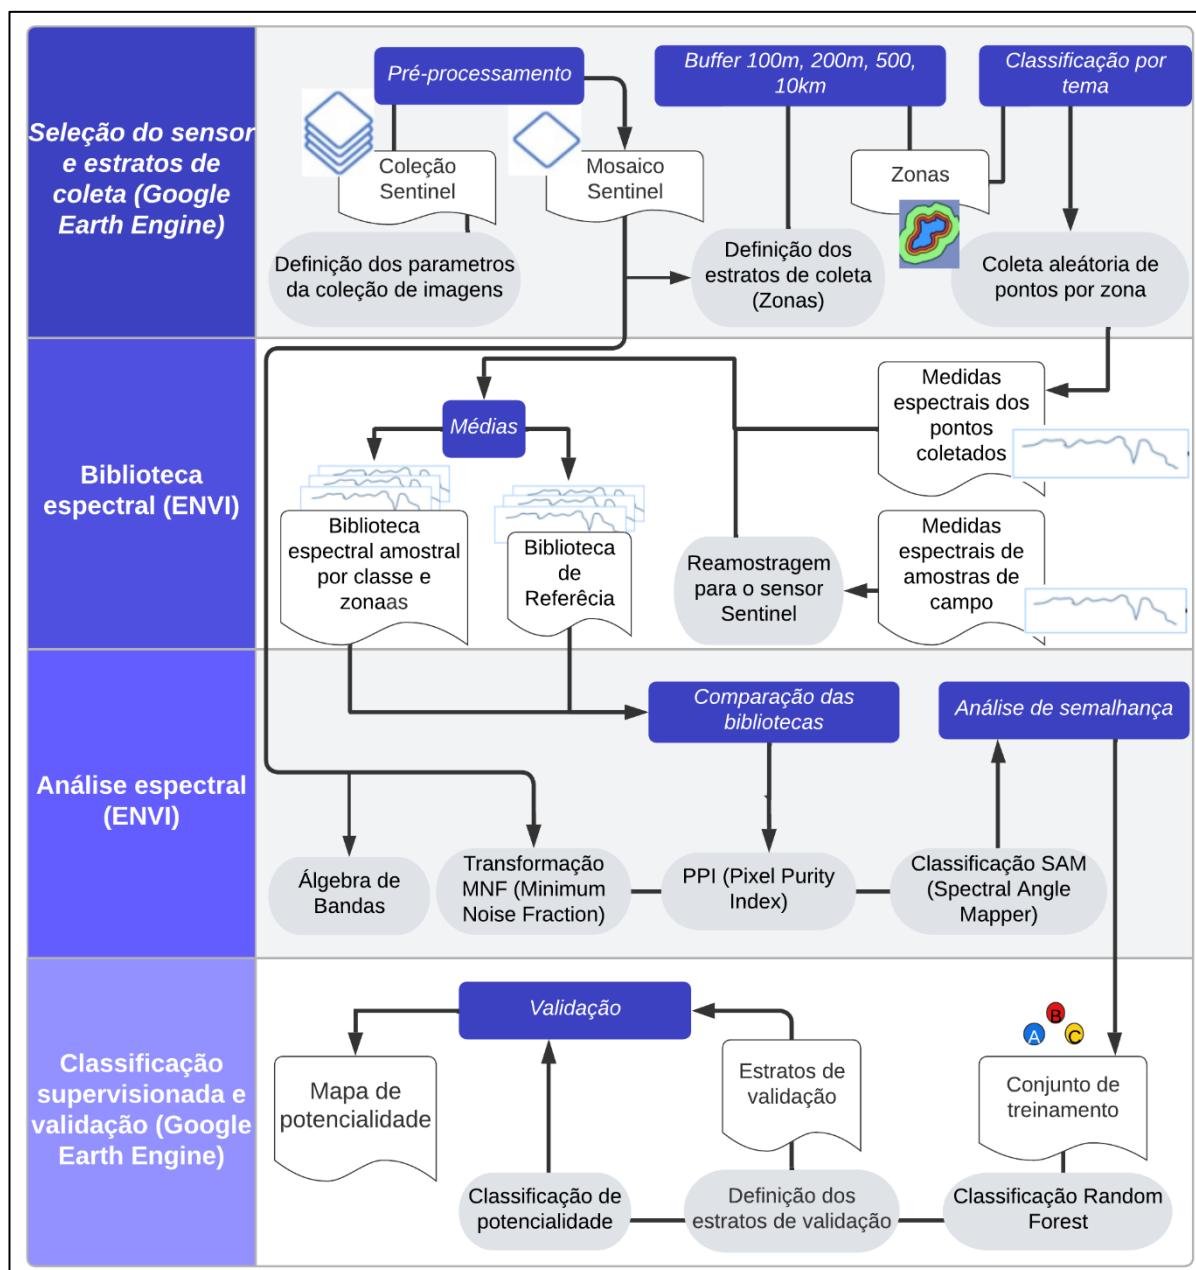


Figura 14 – Fluxograma da metodologia, expondo as diferentes etapas de trabalho e atividades envolvidas.

3.3 RESULTADOS

3.3.1 Comportamento espectral

Os gráficos da dispersão dos pontos referentes aos pixels amostrados das classes de minério, solo, mistura de solo e vegetação e vegetação coletadas na imagem em cada estrato (Figura 15) expõem uma grande variabilidade nos valores da reflectância das classes de minério e solo nos estratos mais próximos das áreas das minas e pouca variação das classes de mistura de solo/vegetação e vegetação.

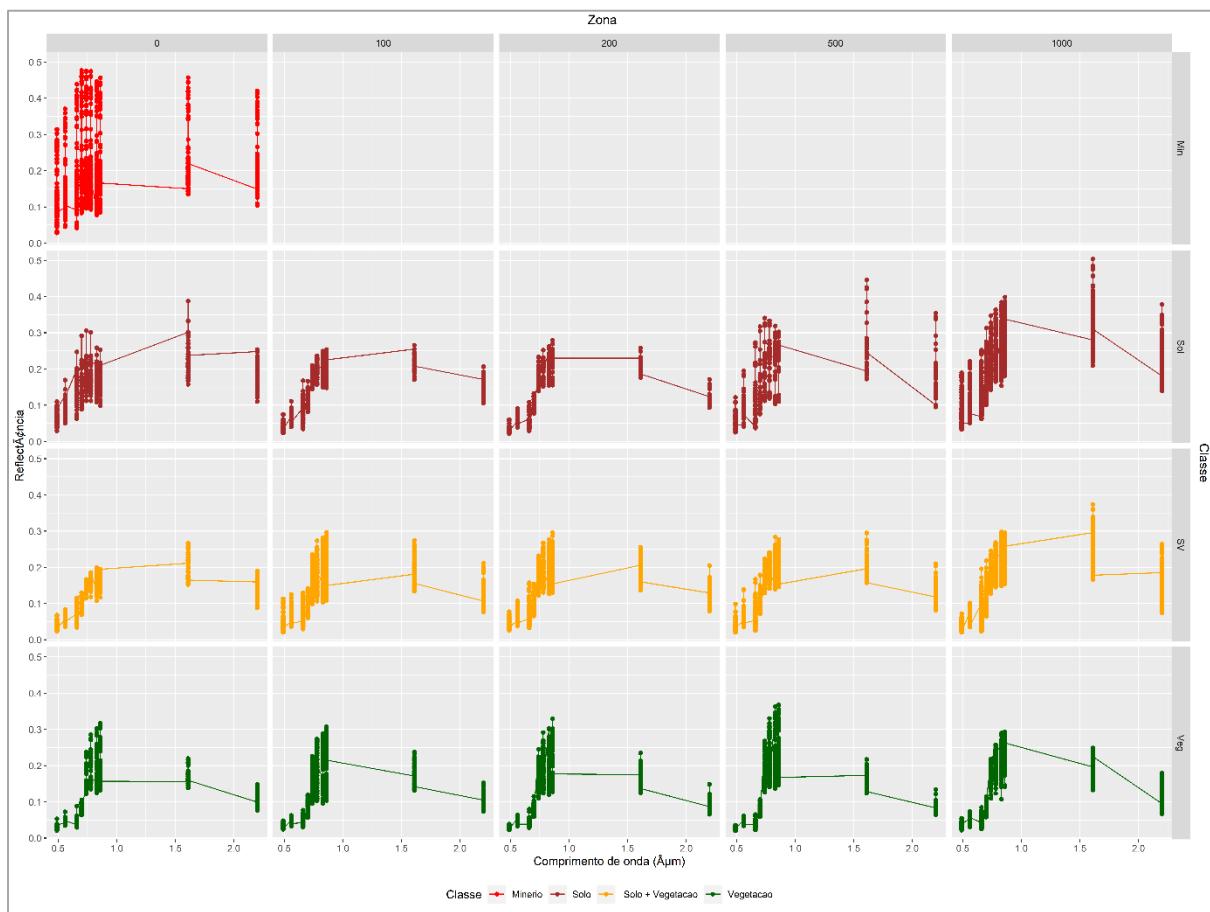


Figura 15 – Gráficos de dispersão dos pontos de pixels representativos de minério, solo, mistura solo/vegetação e vegetação extraídos da imagem nos estratos: (0) zona da área das minas (100) buffer de 100m das áreas das minas, (200) buffer de 200m das áreas das minas, (500) buffer de 500m da área das minas e (1000) buffer de 10km, representando distâncias maiores que 500m das áreas das minas.

As linhas mostram a semelhança entre a curva espectral das amostras de solo no estrato das minas com a assinatura do minério e à medida que se afasta, observa-se uma mudança na feição de reflexão na banda do SWIR, com o aumento dos

valores de reflectância nos estratos mais afastados das áreas das minas. A curva da classe de mistura solo/vegetação no estrato das minas exibe um comportamento mais parecido com a curva do solo no mesmo estrato, entretanto nos estratos seguintes, observa-se um comportamento mais semelhante as curvas da classe da vegetação, que na banda do SWIR, apresenta um aumento do valor da reflectância nos estratos mais afastados das minas.

Foram gerados gráficos das curvas espectrais referentes as amostras das classes de minério, solo, mistura de solo e vegetação e vegetação coletadas na imagem em cada estrato (Figura 16) para avaliar o comportamento espectral das amostras. Os gráficos mostram, em geral, curvas com acentuada feição de absorção nos intervalos entre 0,6 e 0,9 μm , o que indica a presença de ferro. Nas amostras de solo, mistura de solo e vegetação e vegetação, observa-se comportamentos distintos nas feições de absorção das curvas nas bandas do vermelho, infravermelho próximo (NIR) e infravermelhos de ondas curtas (SWIR) entre os estratos, com valores de reflectância mais próximos das amostras de minério nas áreas mais próximas das minas e mais divergentes nos estratos mais distantes.

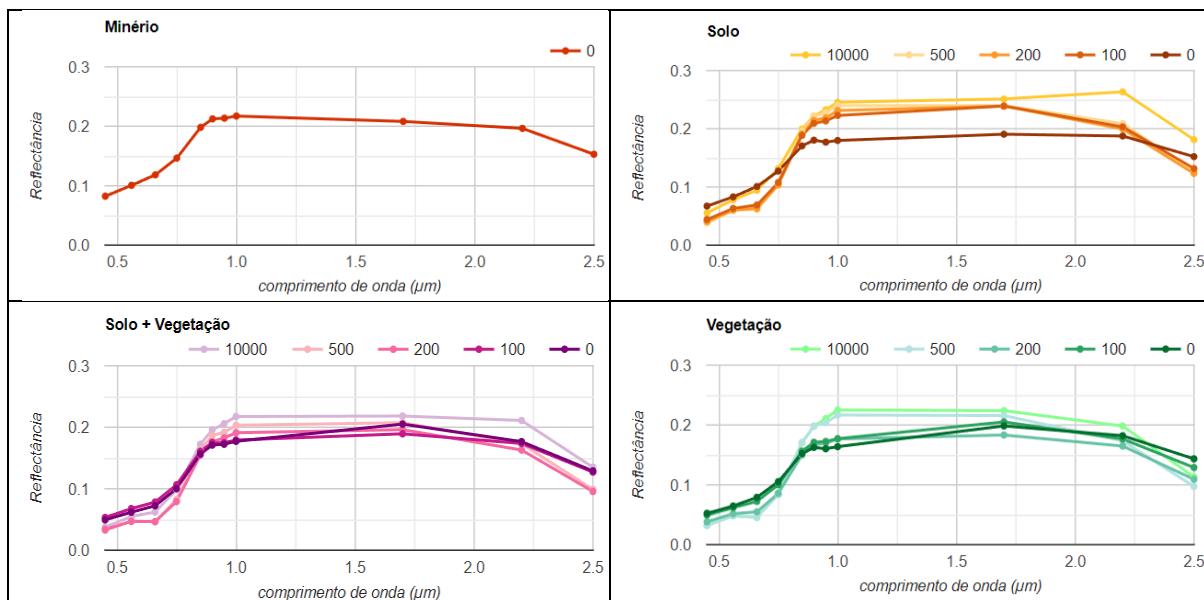


Figura 16 – Assinatura mediana de pixels representativos de minério, solo, mistura solo/vegetação e vegetação extraídos da imagem nos estratos: (0) zona da área das minas (100) buffer de 100m das áreas das minas, (200) buffer de 200m das áreas das minas, (500) buffer de 500m da área das minas e (1000) buffer de 10km, representando distâncias maiores que 500m das áreas das minas.

Foram gerados também, gráficos boxplot para avaliar o comportamento da dispersão dos dados coletados em cada banda da imagem Sentinel (Figura 17).

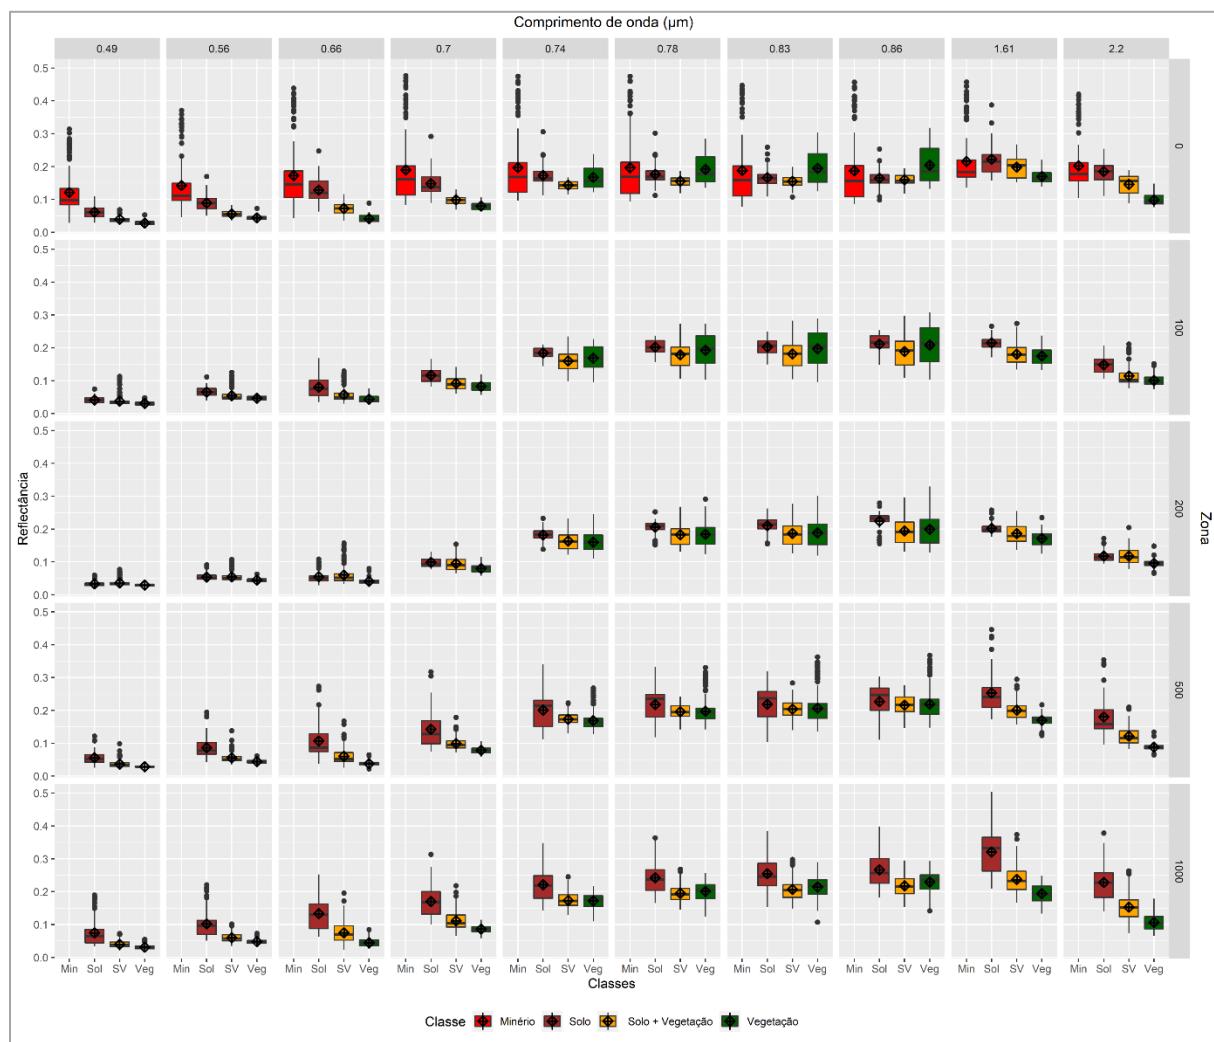


Figura 17 – Gráficos bloxpot dos pontos representativos de minério, solo, mistura solo/vegetação e vegetação extraídos da imagem nos estratos: (0) zona da área das minas (100) buffer de 100m das áreas das minas, (200) buffer de 200m das áreas das minas, (500) buffer de 500m da área das minas e (1000) buffer de 10km, representando distâncias maiores que 500m das áreas das minas.

Através do gráfico é possível entender o comportamento dos dados em cada banda. No estrato da área da mina, os dados referentes ao minério apresentam grande variabilidade nas bandas do vermelho ao NIR, os dados de solo possuem maior variabilidade nas bandas do vermelho e do SWIR, a classe mista de solo e vegetação apresenta maior variabilidade nas bandas do SWIR e os dados de vegetação na região do Red-edge e NIR.

3.3.2 Análise Minimum Noise Fraction (MNF) e Spectral Angle Mapper (SAM)

A rotina de redução do ruído dos dados através da função MNF calculou os autovalores da imagem Sentinel, de tal forma que ordenou os seus conteúdos de informação e ruído. O resultado dessa operação é expresso em forma de uma tabela, onde os números de autovalores calculados estão classificados de forma decrescente, sendo os valores mais próximos de zero representando os ruídos. Aplicando as componentes, correspondentes ao conteúdo de informação geradas, na imagem, é possível obter uma composição colorida onde pode-se identificar as variações tonais dos diferentes tipos de elementos de acordo com os temas das amostras. A técnica SAM permitiu o mapeamento da similaridade entre o espectro de um pixel da imagem e o espectro de referência provenientes das bibliotecas espetrais. Com isso, foram obtidos os índices (endmembers) correspondentes aos materiais de referência que espectralmente predominam no píxel, apresentados na forma de uma tabela (Anexo 2), mostrando a ordem de semelhança com o tipo de amostra da biblioteca de referência referente as classes de cada estrato. A figura 18 sintetiza os resultados de acordo com a classe, percentual de semelhança e estrato de coleta.

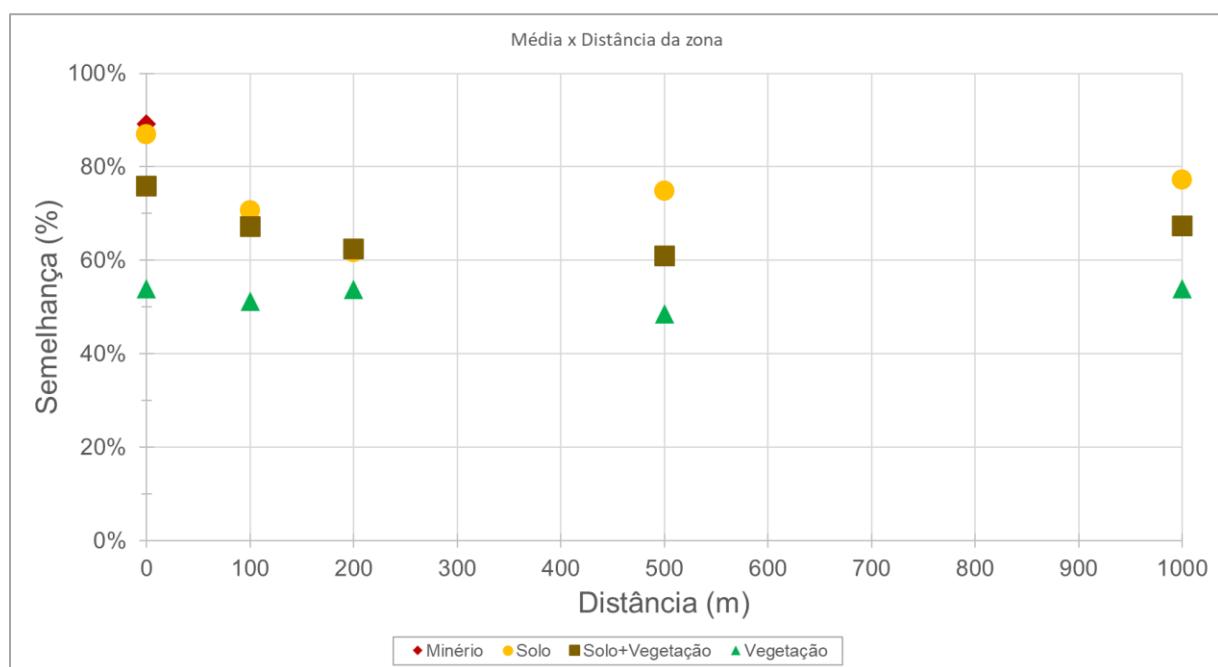


Figura 18 – Gráficos da semelhança dos valores médios das classes com a biblioteca espectral X zona de distância (estratos de amostragem).

3.3.3 Classificação Random Forest

Os resultados do processamento utilizando o Random Forest mostram o mapeamento das áreas de potencialidade para ocorrência de depósitos de ferro bem distribuídos ao longo do estado (Figura 19).

A análise localizou zonas de média potencialidade entre as cidades de Caetité e Licínio de Almeida, pertencentes ao Distrito do Sudoeste da Bahia. Esses corpos se alinham em um *trend* norte-nordeste a sul-sudoeste, de aproximadamente 150 km de comprimento. Ainda nessa região, é possível notar duas ramificações de áreas potencialmente baixas, sentido norte-noroeste. Ao sul de Brumado, é possível observar clusteres de áreas, com a predominância de baixa potencialidade, que à medida que se estendem sentido norte-noroeste, passando por Piatã e terminando em Boninal, aumentam o potencial ferrífero.

No Distrito do Sudeste da Bahia, uma faixa de orientação norte-sul com média potencialidade é observada. Se estende desde ao norte de Jequié e diverge próximo de Iguaí, sentido nordeste-sudoeste em direção a Vitoria da Conquista e ao norte-noroeste a sul-sudeste até Itapebi. É possível notar, nessa região a ocorrência de mais dois *trends* paralelos ao de Jequié-Iguaí.

Próximo a capital, no triangulo formado pelas cidades de Nazaré, Coração de Maria e Mundo Novo, zonas de formato lenticular se estendem, sentido norte-noroeste a sul-sudeste. Essas zonas, pertencentes ao Distrito do Recôncavo, foram mapeadas com níveis variando de baixo a médio grau de potencialidade e se ramificam em direção as cidades de Queimadas e Jaguarari, mais ao norte do estado.

No norte do estado, a análise mapeou a faixa correspondente ao Distrito ferrífero Norte, localizado próximo das cidades de Remanso e Sento Sé. Essa área se estende sentido nordeste-sudoeste até a região próximo de Santa Rita de Cássia, com um aumento gradativo do nível de potencialidade mineral.

Na figura 20, o mapa de potencialidade foi sobreposto com as delimitações dos distritos sugerido por Ribeiro (2017), áreas das poligonais de requerimentos de lavra e pesquisa junto a ANM, bem como pontos referentes as localizações de ocorrência

mineral. Em geral, o processamento conseguiu mapear áreas dentro dos distritos conhecidos e além deles, observado no mapa entre as cidades de Caetité e Jequié, porção intermediária aos distritos Sudoeste e Sudeste. Outras regiões fora dos distritos incluem uma zona descontínua ao norte do Distrito do Recôncavo, próximo a Macururé e uma faixa que se estende de Sobradinho a Umburanas.

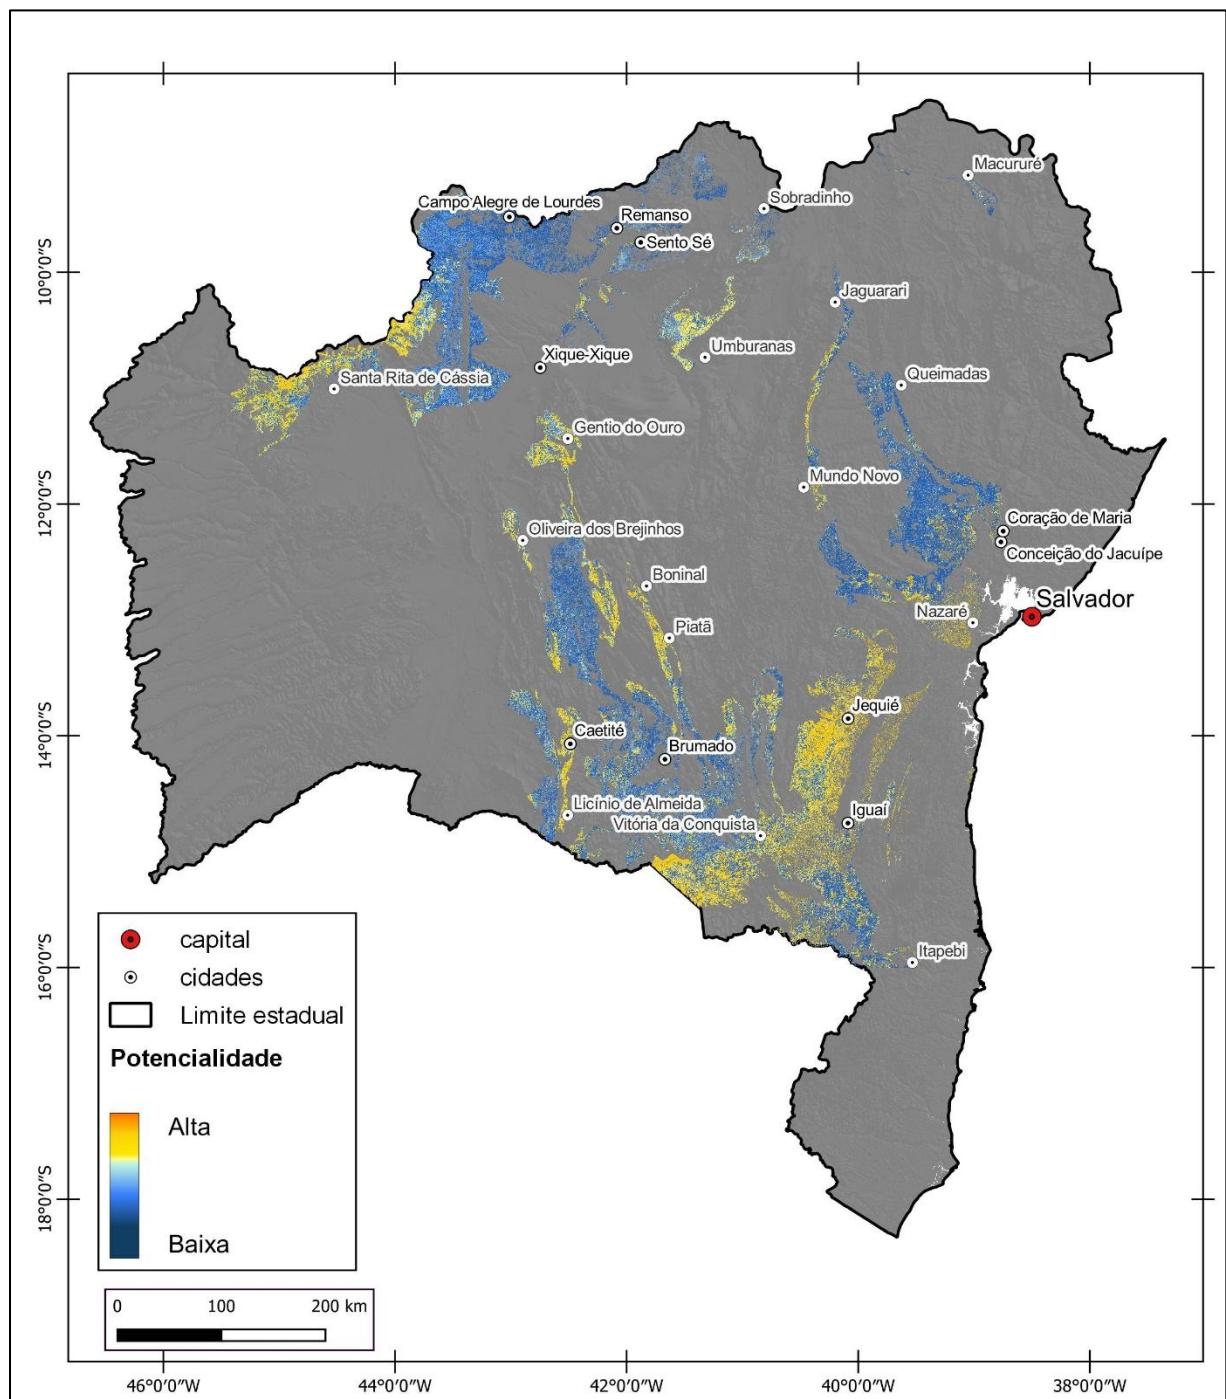


Figura 19 – Mapa de potencialidade para ferro na área de estudo

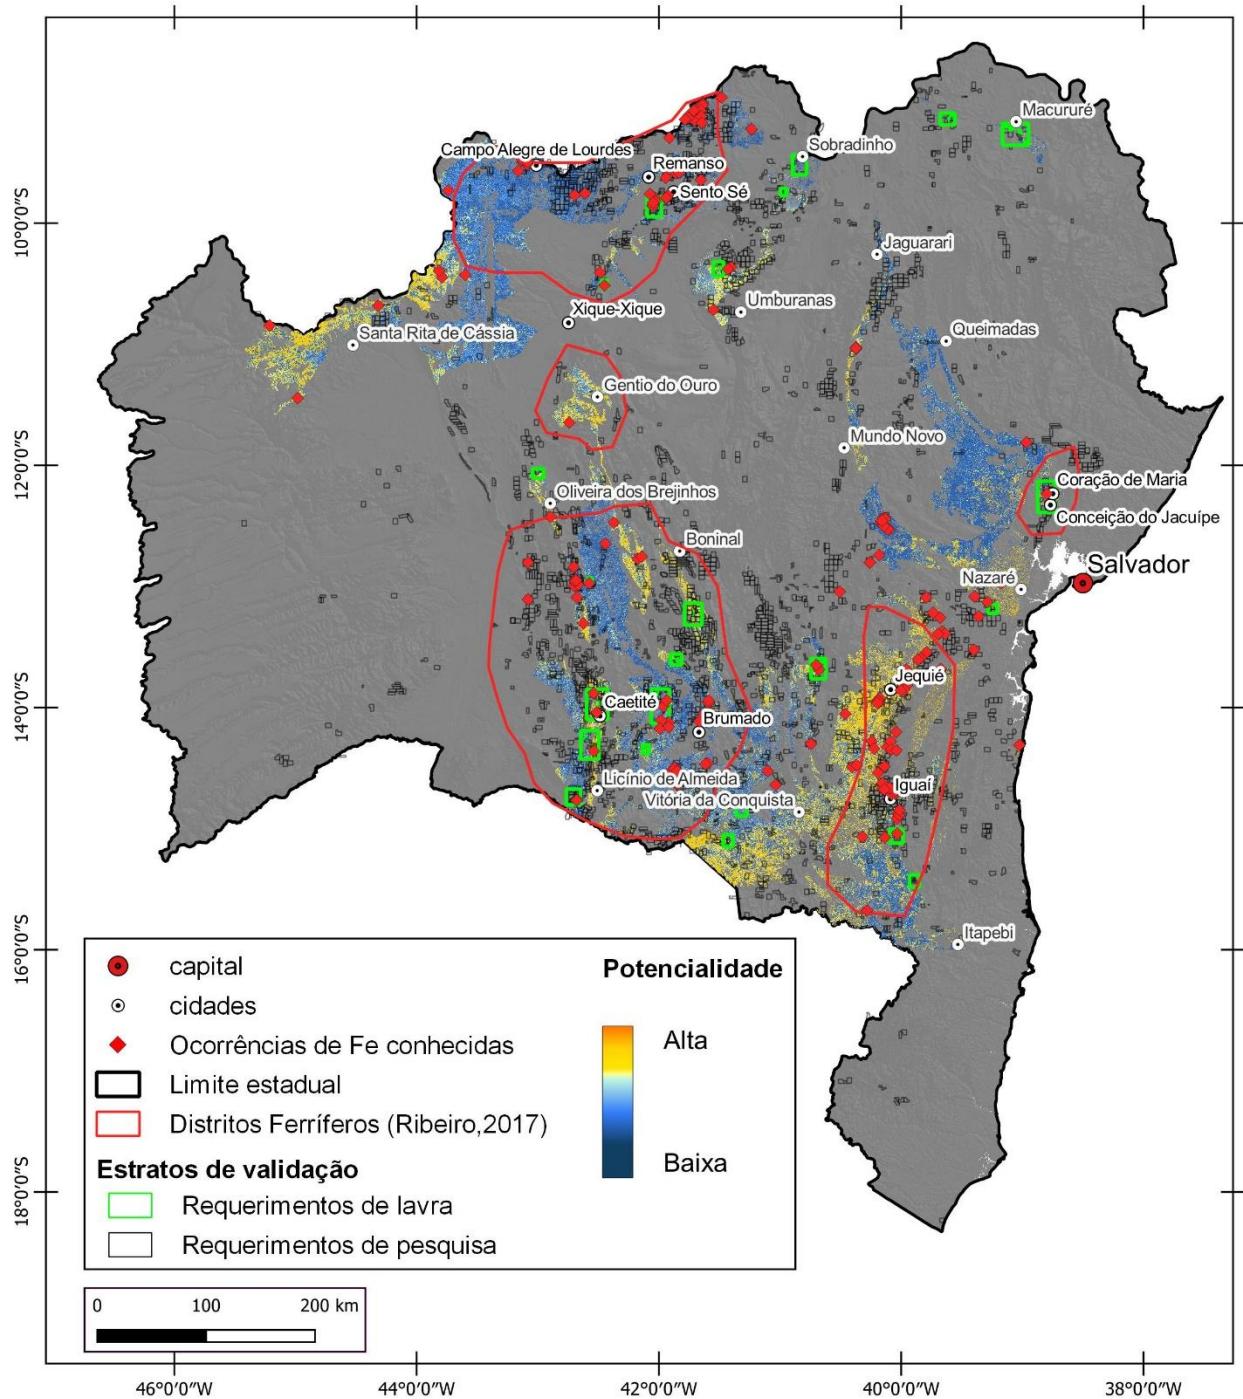
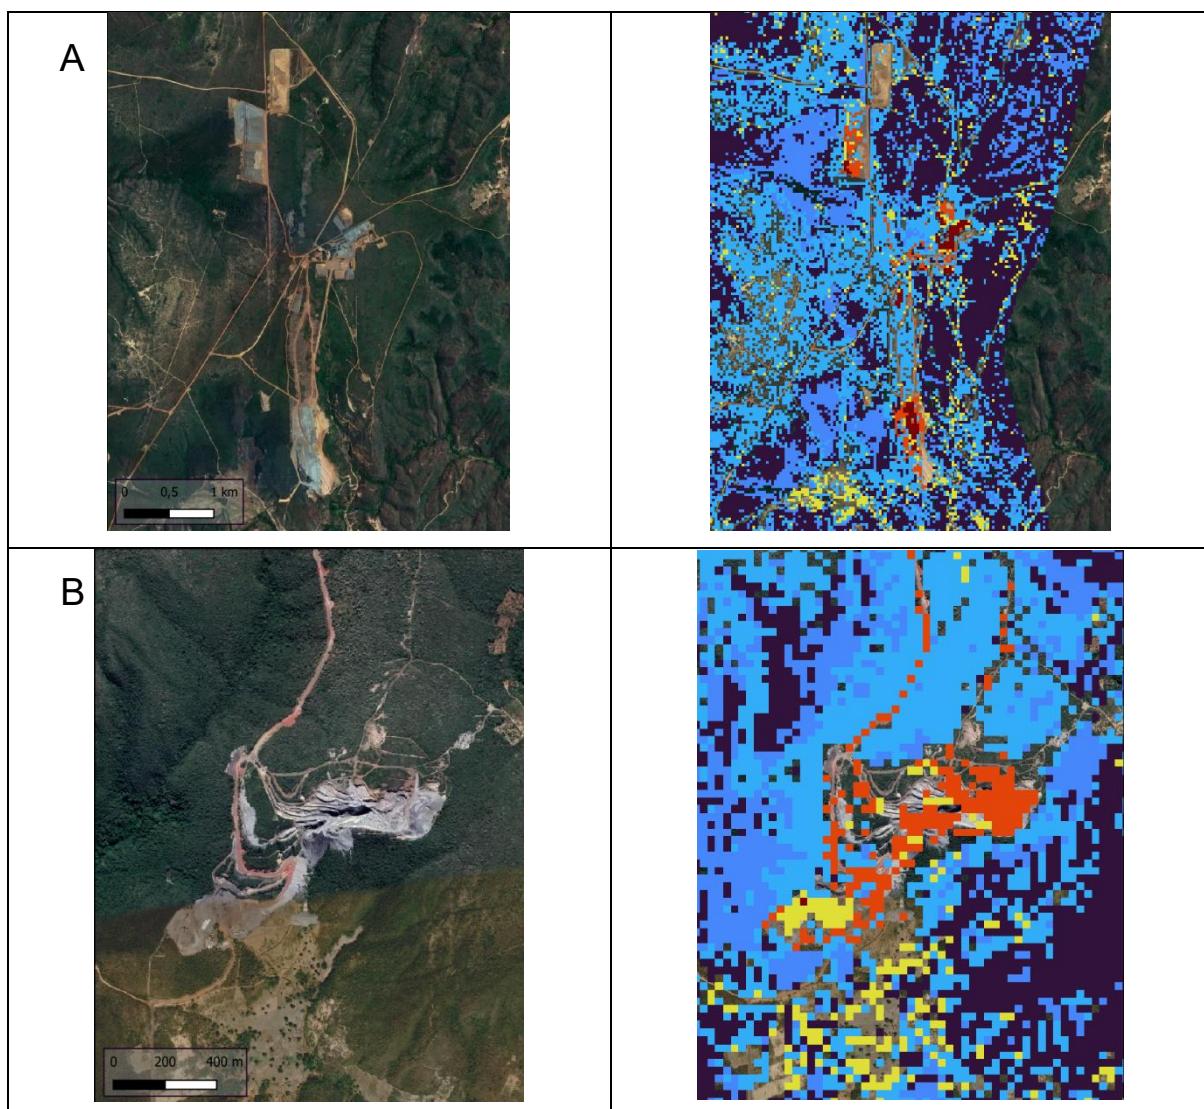


Figura 20 – Mapa de potencialidade para ferro na área de estudo sobreposta a imagem SRTM sombreada, destacando os pontos de depósitos conhecidos e as poligonais de requerimentos de lavra e de pesquisa

3.3.4 Validação

As poligonais de requerimentos minerários foram utilizadas para verificar a consistência do modelo. Para as poligonais nas fases de concessão de lavra temos as minas Pedra de Ferro e Mocó, utilizadas no treinamento, que estão representadas nas figuras abaixo (Figura 21a e 21b), com o mais alto potencial (vermelho) coincidindo com o minério exposto na área das cavas. Este mesmo padrão é observado em outras minas não incluídas no treinamento (figuras 21c, 21d e 21e), respectivamente, a Largo (Fe-Ti-V, Vanádio Mineração S/A), Mina Andorinha (Cr, Ferbasa) e a Mina Caraíba (Cu, Caraíba Metais), que embora suas substâncias principais mineradas não sejam o ferro, as jazidas minerais em questão estão associadas a formações ferríferas lavradas como substância secundária, portanto, existe a presença de Fe mineral.



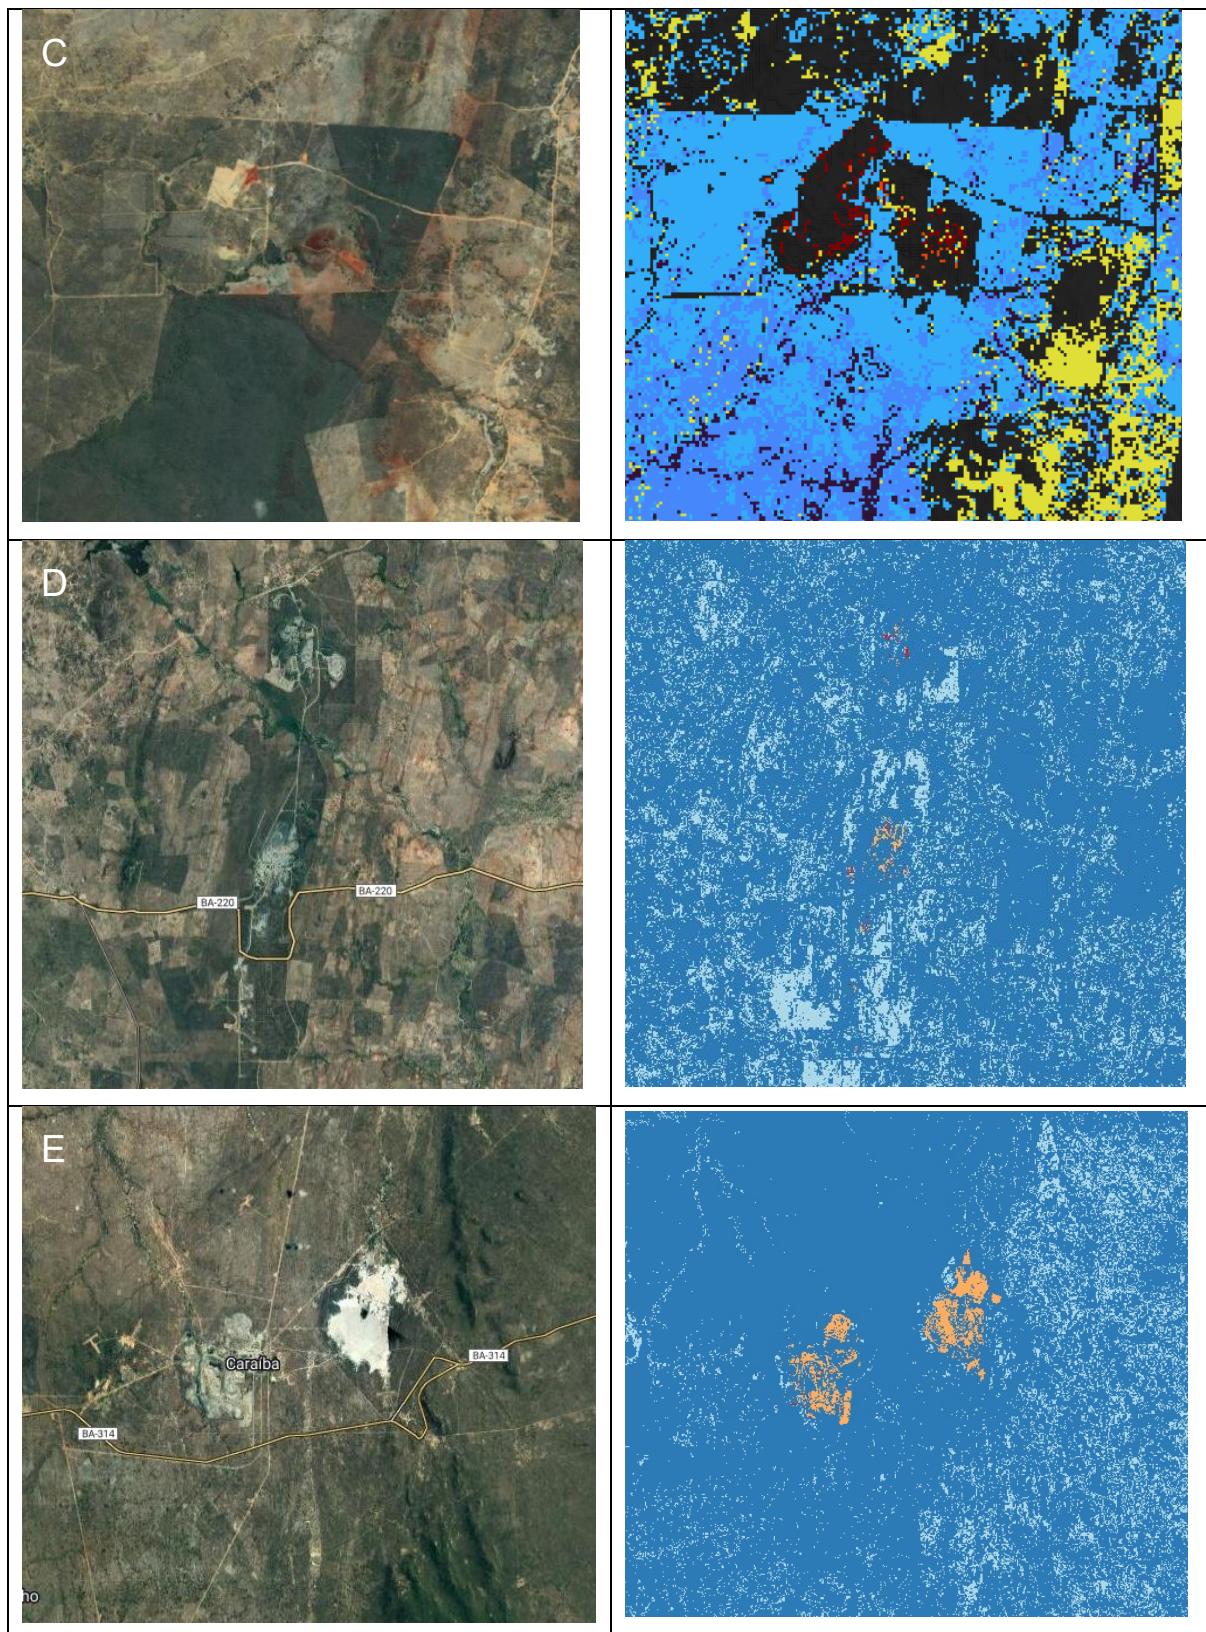


Figura 21 – Comparação das áreas de concessão de lavra com imagens de alta resolução (Google). (A) Mina Pedra de Ferro, (B) Mina Mocó, (C) Mina vanádio de Maracás (Largo), (D) Mina Andorinha e (E) Mina Caraíba

As áreas referentes as poligonais nas fases de requerimento de lavra ainda não possuem uma cava aberta, no entanto, são locais onde já existe uma prospecção avançada, com abertura de picadas e trincheiras. O distrito ferrífero do sudoeste da Bahia (Figura 22) mostra as zonas de onde estão próximos os depósitos conhecidos, exibindo valores de média-alta potencialidade no mapa. Adicionalmente, foram identificados potenciais zonas de interesse, embora não exista nenhuma mineralização de Fe conhecidas até agora nessas áreas.

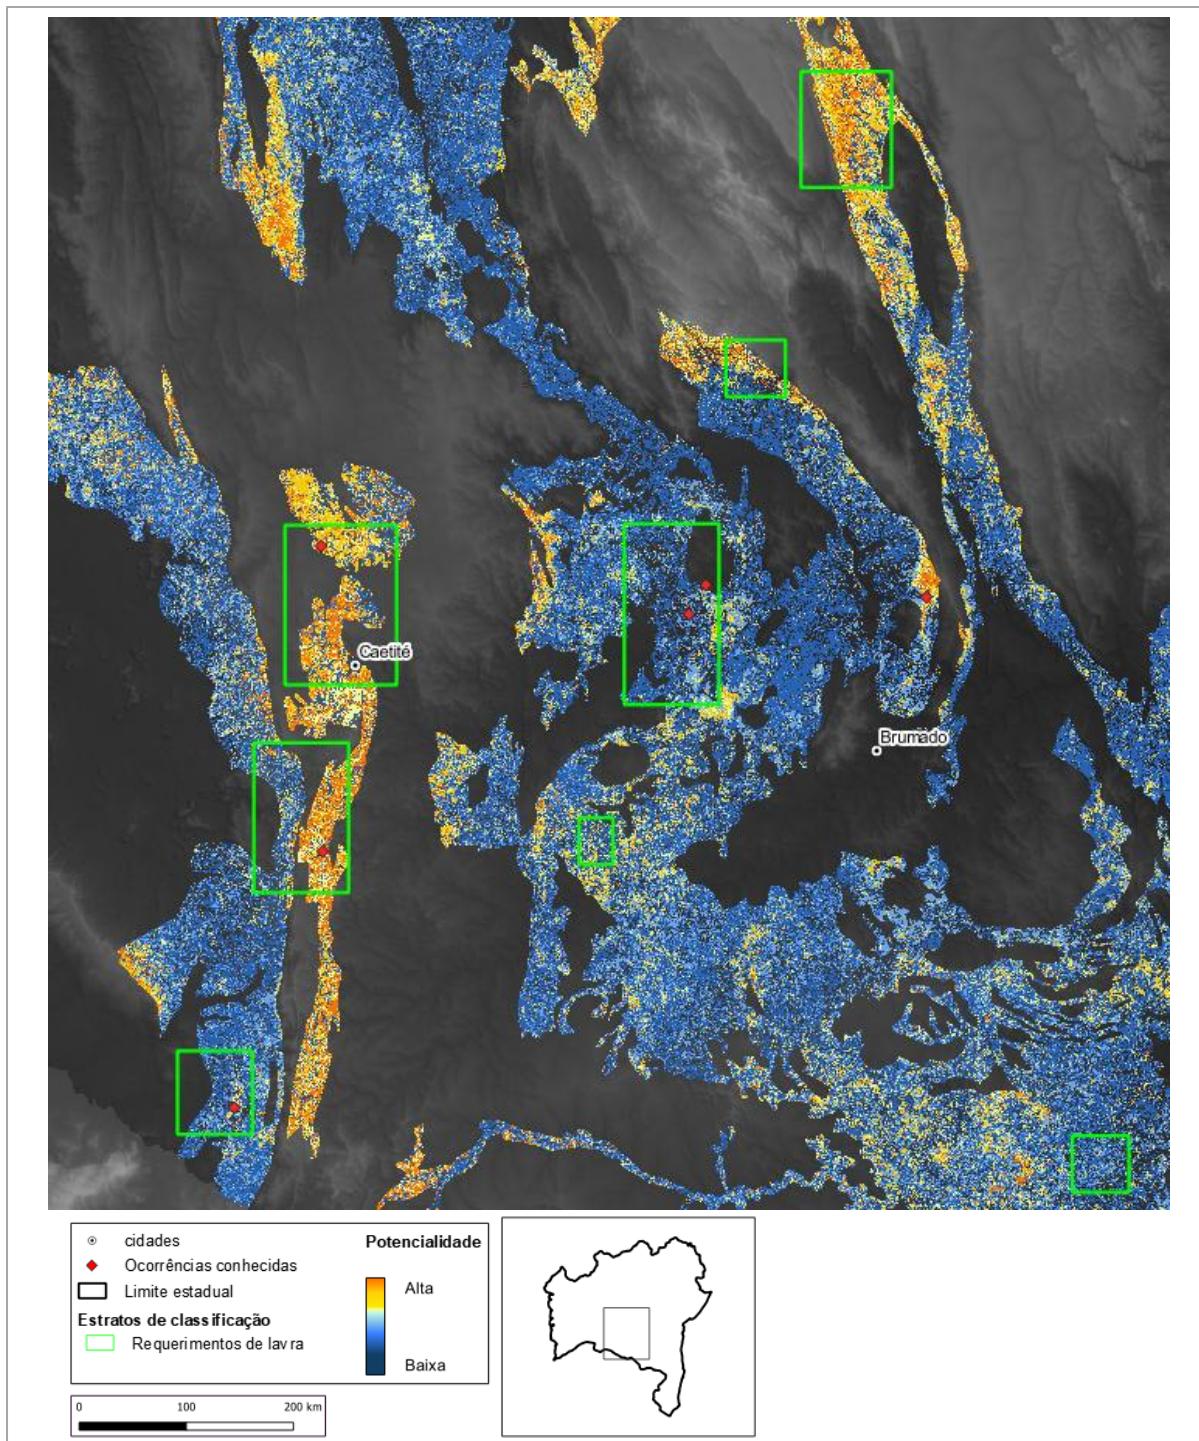


Figura 22 – Mapa de potencialidade para Fe no distrito ferrífero do sudoeste da Bahia.

O distrito ferrífero do norte da Bahia (Figura 23) mostra as zonas de onde estão próximos os depósitos conhecidos, onde Dalton de Souza (Souza *et al.*, 1979) realizou os primeiros registos de ferro significativos no Complexo Colomi e que se estendem até a Serra da Capivara no sul do Piauí, representadas pelas setas vermelhas. As áreas referentes as setas azuis representam os depósitos do Morro do Urubu, onde, desde 2018, ocorre a implantação de lavra pela empresa BR Ferro Mineração Ltda., subsidiaria da australiana Brazil Iron. Observa-se uma faixa com valores médios a altos de potencialidade da porção oeste do distrito, referentes as coberturas sedimentares detrito-lateríticas ferruginosas.

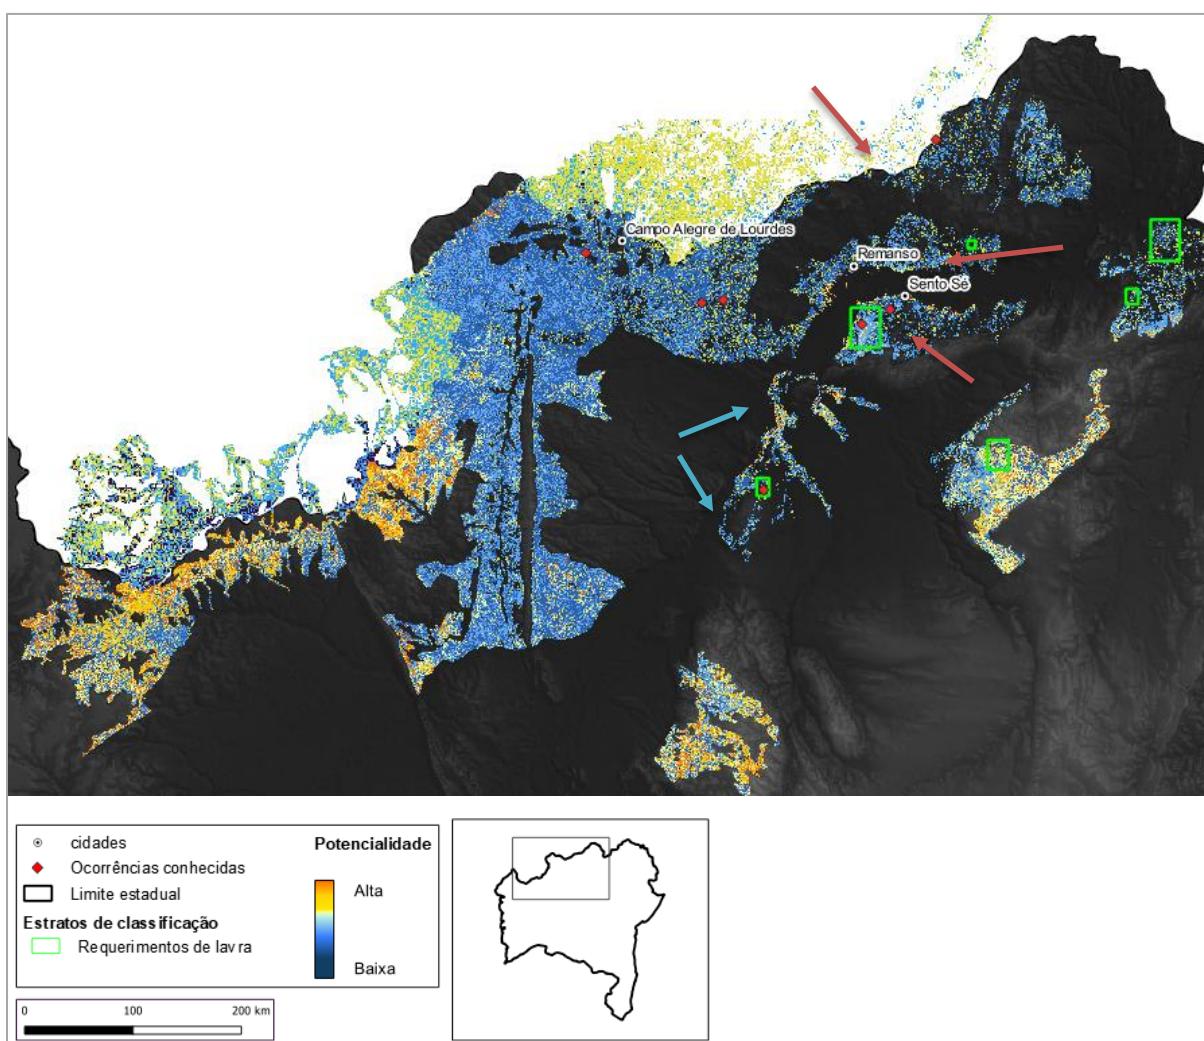


Figura 23 – Mapa de potencialidade para Fe no distrito ferrífero do norte da Bahia.

Para as poligonais nas fases de requerimento de pesquisa, foram levantadas 3132 áreas requeridas. Destas, 1674 (53,44%) estão inseridas em regiões de potencialidade para ferro (Figura 24). Observa-se que os agrupamentos de

requerimentos realizados no mesmo período, próximos aos principais depósitos do estado, provavelmente correspondem as áreas requeridas pelas mineradoras detentoras das áreas de concessão de lavra da região. Ao redor dessas áreas estão dispersos requerimentos realizados no período subsequente. Os agrupamentos de requerimentos efetuados no período entre 2020 e 2022 sugerem novas etapas de pesquisa no estado.

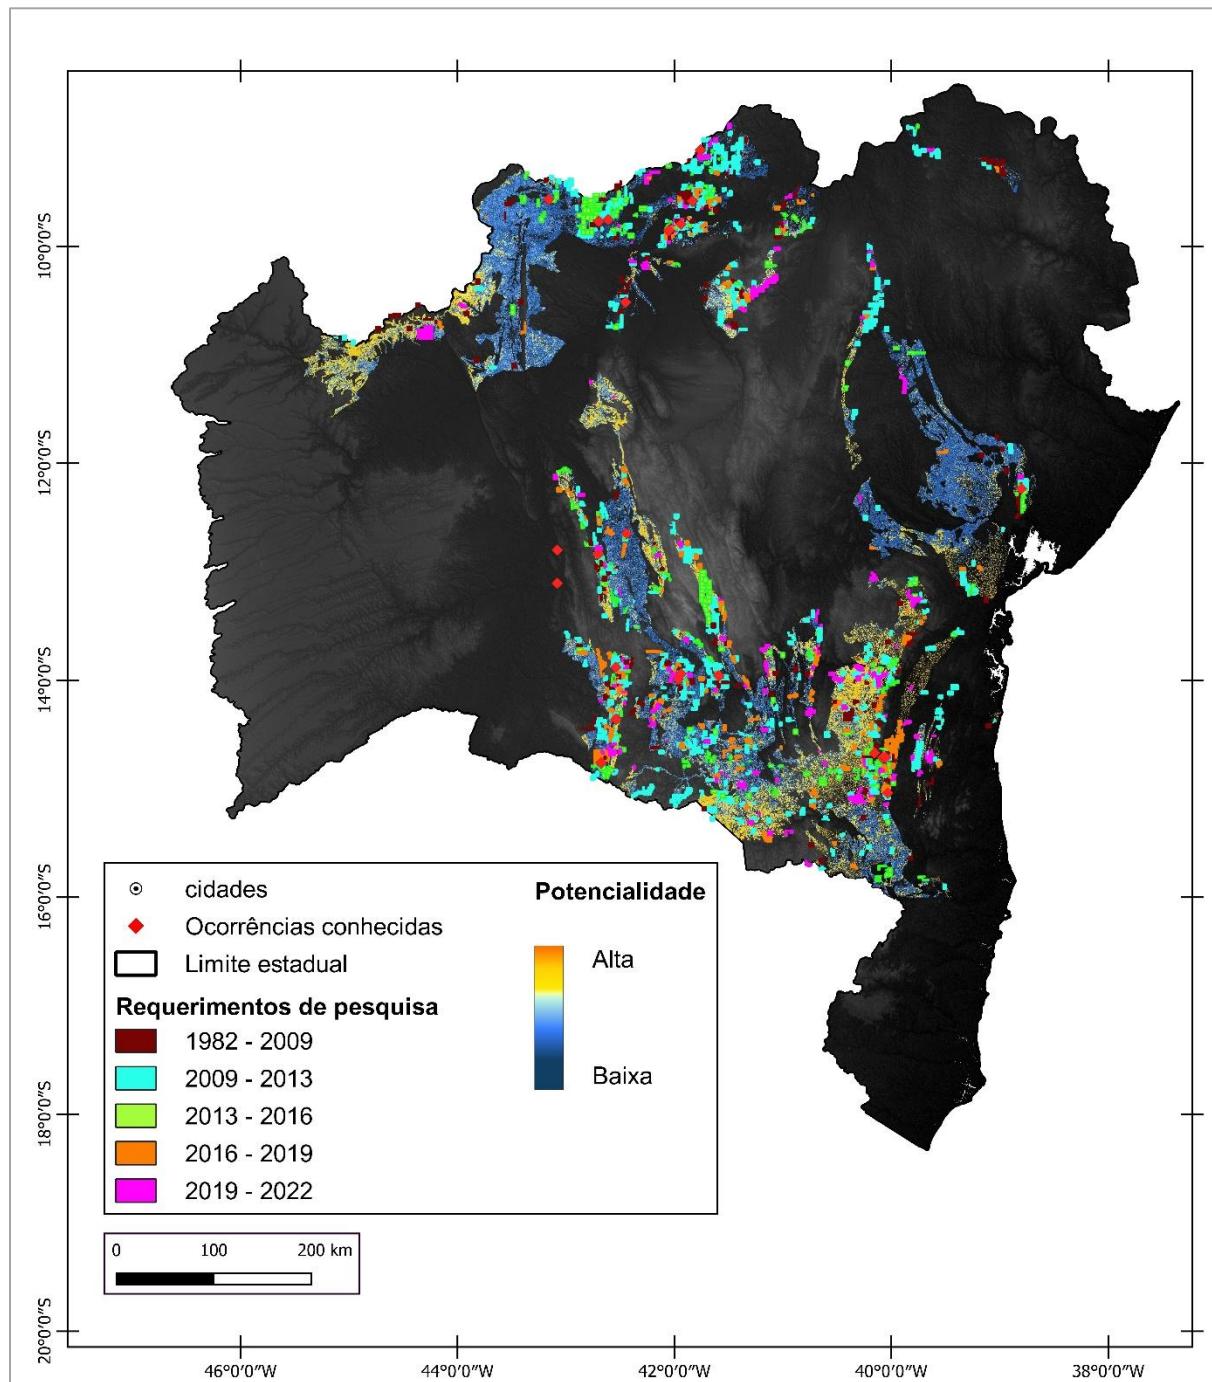


Figura 24 – Mapa de potencialidade para Fe e os requerimentos de pesquisa mineral.

A avaliação de acurácia, com 175 pontos aleatórios em cada tema estudado. foram geradas a matriz de confusão e, a partir dessa, foram calculadas as métricas de acurácia (Tabela 5). As principais omissões foram nas classes de solo exposto nos estratos maiores que 500m da área das minas, possivelmente atribuída a predominância de pixels com similaridade espectral com os solos enriquecidos em Fe. O valor da Exatidão Global calculada foi de 69,80%.

Tabela 5 – Tabela da matriz de confusão das classes de potencialidade. 1-Min (Minério), 2-Sol+(Solo com alto Fe), 3-Sol- (Solo com baixo ferro), 4- SV+(Solo e vegetação com alto Fe), 5- SV-(Solo e vegetação com baixo ferro), 6- Veg+ (Vegetação com alto ferro), 7- Veg- (Vegetação com baixo ferro).

	Real	Min	Sol+	Sol-	SV+	SV-	Veg+	Veg-
Mapa								
Min	1	0	0	0	0	0	0	0
Sol+	0	0,31	0,28	0,24	0,17	0	0	0
Sol-	0	0,26	0,56	0,16	0,10	0	0	0
SV+	0	0	0	0,75	0,35	0	0	0
SV-	0	0	0	0,08	0,92	0	0	0
Veg+	0	0	0	0	0	0,68	0,32	
Veg-	0	0	0	0	0	0,34	0,66	

3.4 DISCUSSÃO

Os resultados do mapeamento de potencialidade apontam certa coerência quando comparada com a geologia do estado. As formações ferríferas do Distrito Sudoeste (Caetité-Brumado), que incluem a região da Mina Ferro de Pedra, estão intercaladas com as sequências metavulcanossedimentares do Complexo Licínio de Almeida (Lanfranchi et al., 2017). Essa região é representada, no mapa, pelo *trend* NNE-NNW delineando o flanco oriental da Serra do Espinhaço.

As áreas com potencialidade para mineralizações ferríferas do Distrito Sudeste (Iguaí-Jequié) foram razoavelmente bem delimitadas. O mapeamento conseguiu distinguir os temas e os diferentes níveis de sinal de ferro, como o minério nas áreas de lavra e os traços de Fe em áreas de vegetação densa. Segundo Ribeiro (2017), os depósitos desse Distrito estão em três faixas, paralelamente alinhados

sentido NNE, denominadas Serra do Ouro, Boa Esperança e Itororó-Rio Novo. Essas áreas coincidem com os *trends* NNW-SSE identificados no mapa ao leste de Jequié e Iguaí. A extensa região mapeada com média potencialidade, que inclui as áreas próximas ao sudoeste de Jequié, passando por Vitoria da Conquista, se estendendo até a divisa do estado correspondem a coberturas detrito-lateríticas ferruginosas associadas a Unidade Ribeirão da Folha.

No Distrito do Recôncavo, o mapeamento incluiu áreas do Complexo Santaluz, próximas a Mina Jacuípe, em Coração de Maria, mas também incluiu grande porção do Complexo Caraíba, representados nos clusters próximos a Nazaré e seguindo ao norte, sentindo Queimadas. Essas litologias englobam ortognáisses félsicos, enriquecidos em ferro, cálcio e magnésio (Teixeira, 1997). Embora, não exista registro de ocorrências de depósitos de ferro. O mapeamento também incluiu áreas referentes ao *Greenstone Belt* do Rio Itapicuru (Carvalho, 2010), que inclui as áreas da Mina Andorinha (Cromo) e a Mina Caraíba (Cobre), das quais, existem ocorrência de minerais com ferro, mas considerados como substâncias secundárias em ambas as minerações.

No Distrito Norte (Sento Sé-Remanso), o Complexo Colomi, das fácies óxido e carbonato, é destacada pelo das superfícies onduladas e pediplanas da topografia de pediplano. As formações ferríferas lateríticas apresentam ausência ou presença insignificante de detritos terrígenos (Souza et al, 1979). O mapeamento apresentou boa sensibilidade à variação detrito-laterítica das coberturas ferruginosas, ao conseguir detectar os diferentes níveis de potencialidade de forma gradativa, acompanhando o mesmo sentido do *trend* norte do Craton São Francisco.

Segundo Santana (1974), os BIFs observados no estado da Bahia são classificados em: a) Itabiritos Siliciosos, rochas com bandas ferrosas intercaladas com bandas quartzosas, com teores médios de Fe entre 30% e 45%; b) Itabiritos Dolomíticos, bandas dolomíticas intercaladas por bandas de óxido de ferro, com teores médios de Fe entre 30% e 35%; c) Itabiritos Anfibolíticos, correspondem a intercalação de bandas ferríferas com rochas metabásicas, com teores médios variando entre 25% a 32%; d) Magnetititos, Hematititos e Itabiritos Magnetíticos-Hematíticos, rochas associadas a atividade hidrotermal, com baixa quantidade de sílica, são as BIFs que apresentam maiores teores, variando entre 50% a 67% de Fe;

e) Minério supergênico, formações ferríferas lateríticas, formadas pela lixiviação dos minerais de ganga pela água da chuva, formando um enriquecimento supergênico em óxido de ferro, com teores médios de 30% a 50%.

A etapa da validação foi importante para avaliar a qualidade do mapeamento. Além do cálculo da acurácia global, a fase de análise por averiguação serviu para revelar estimativas das taxas de acerto e de erro para classe mapeada. Em geral, o mapeamento apresentou bons resultados. Mesmo assim, foram observadas diversas áreas possivelmente falso-positivas, alguns pixels muito claros podem ser mapeados como solos ricos em Fe. Entretanto, algumas áreas apresentadas nesse trabalho, como ao norte do estado, próximo da cidade de Macururé e ao oeste do Distrito Norte, em Santa Rita de Cássia, apresentam potencial. Além de seguir na mesma direção do sentido da sequência de falhas NE do Cráton São Francisco, a grande quantidade de requerimentos de pesquisa, aglomerados nessas regiões, podem sugerir uma maior atenção.

Neste trabalho não foi considerada a variação mineralógica entre as diferentes rochas das unidades litoestratigráficas do estado e a pouca diferenciação na assembleia mineral identificada nas medições espectrais pode ter causado um problema de identificação na classificação, uma vez que suas diferenças espectrais não foram tão evidentes, o que resultou em uma dificuldade na distinção das rochas mineralizadas de suas encaixantes. Além disso, a quantidade de falsos positivos pode ter sido agravada pela existência de outros elementos na região de estudo, como as áreas urbanizadas e pela grande ocorrência de ferro laterítico disseminados nos solos superficiais.

Analisando os dados do Sigmine, observa-se que em determinados períodos (2010-2015, 2016-2019 e 2020-2022), houve um aumento significativo dos requerimentos de pesquisa junto a ANM (Agência Nacional de Mineração), provavelmente incentivado pela alta dos preços das *commodities* de minério de ferro no mercado internacional. A grande dispersão das áreas requeridas no território do estado, com destaque de concentrações de requerimentos fora das áreas dos distritos ferríferos conhecidos sugere a existência de práticas de especulação, uma vez que, na maioria dos casos, esses requerimentos encontram-se aos arredores de áreas requeridas por mineradoras de grande porte, sem deixar de mencionar que em muitos

não há uma análise técnica qualificada. Embora exista a possibilidade de jazidas ferríferas ainda não estudadas ou que as extensões dos distritos de ferro existentes sejam ainda maiores do que as atuais delimitações.

3.5 CONCLUSÕES

A espectrorradiometria de reflectância demonstrou ser uma ferramenta útil no auxílio da discriminação das diferentes classes ao analisar as curvas de assinaturas espetrais. A utilização conjunta dos classificadores SAM e RF possibilitou a caracterização na imagem dos diferentes tipos de classes de minério, solo e vegetação com altos e baixos teores de ferro, o que resultou no mapeamento de zonas coincidentes com as áreas dos alvos conhecidos. No processamento digital das imagens Sentinel, o mapeamento permitiu discriminar diferentes traços de ocorrência de Fe entre os temas da imagem, o que apresentou resultados satisfatórios, especialmente quando comparados com informações de depósitos já conhecidos, mostrando coerência, principalmente os alvos prospectivos de alta relevância para exploração mineral. Os produtos gerados por este trabalho fornecem subsídios para sua interpretação, inclusive podendo gerar outros produtos que possam ser posteriormente submetidos a outros processamentos. O mapeamento espectral, assim como todo produto proveniente de técnicas de sensoriamento remoto, serve como diretrizes para orientar os estudos de pesquisa mineral, havendo a necessidade de um aprofundado estudo geológico de detalhe, em forma de etapas de campo, sondagens e amostragem das rochas existentes nas novas áreas sugeridas. Entretanto, por ser um método de avaliação relativamente rápido e barato, e a sua tecnologia está sempre se renovando, seus dados são atualmente críticos para a modelagem do meio ambiente voltada para exploração mineral.

REFERÊNCIAS BIBLIOGRÁFICAS

- AB'SÁBER, N.A. *O domínio morfoclimático semiárido das caatingas brasileiras*. Instituto de Geografia / USP, São Paulo (Série Geomorfologia, 43), 1974.
- ADAMS, S.S., 1985. **Using Geological Information to Develop Exploration Strategies for Epithermal Deposits**, Geology and Geochemistry of Epithermal Systems, B. R. Berger, P. M. Bethke. Society of Economic Geologists. V.2, DOI: <https://doi.org/10.5382/Rev.02>.
- ALVES, J. E. S. **Mapeamento geológico e análise estrutural multiescalar do cinturão de dobramentos e cavalgamentos da Serra do Espinhaço Setentrional, Caetité, Bahia**.112 f. Trabalho Final de Curso (Bacharelado em Geologia)-Instituto de Geociências, Universidade Federal da Bahia, Salvador, 2008.
- AMOS B. J.; GREENBAUM D. ,1989. **Alteration detection using TM imagery The effects of supergene weathering in an arid climate**, International Journal of Remote Sensing, 10:3, 515-527, DOI: 10.1080/01431168908903889
- AHMADI, H.; PEKKAN, E., 2021. **Fault-Based Geological Lineaments Extraction Using Remote Sensing and GIS-A Review**. Geosciences.11. 183. 10.3390/geosciences11050183.
- BEDINI, E., 2022. **The use of hyperspectral remote sensing for mineral exploration: a review**. Journal of Hyperspectral Remote Sensing, [S.I.], v. 7, n. 4, p. 189-211, dec. 2017. ISSN 2237-2202.
- BIONDI, J. C. **Processos metalogenéticos e os depósitos minerais brasileiros**. São Paulo: Oficina de Textos, 2003. 528 p.
- BONHAM-CARTER, G. F. **Geographic information systems for geoscientists**. Modeling with GIS, pp.398, Pergamon, United Kingdoms. 1994.
- BRANDMEIER, MELANIE & CHEN, Y. 2019. **LITHOLOGICAL CLASSIFICATION USING MULTI-SENSOR DATA AND CONVOLUTIONAL NEURAL NETWORKS**. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLII-2/W16. 55-59. 10.5194 / isprs - archives - XLII-2-W16-55-2019.
- BRASIL, Secretaria de Geologia, Mineração e Transformação Mineral (DTTM), Ministério de Minas e Energia (MME). **Boletim do Setor Mineral – Abril de 2020**. 3º Edição, Brasília, 2020, 32p.
- BRASIL. Agência Nacional de Mineração (ANM). **Anuário Mineral Brasileiro: principais substâncias metálicas** / Agência Nacional de Mineração; Brasília: ANM, 2023. 23 p.; il. Ano Base 2021
- CARVALHO, L.; RAMOS, M. **Geodiversidade do estado da Bahia**. Salvador: CPRM, 2010. [184] p. il., color

CATÉ, ANTOINE & PEROZZI, LORENZO & GLOAGUEN, ERWAN & BLOUIN, MARTIN. 2017. **Machine learning as a tool for geologists**. The Leading Edge. 36. 215-219. 10.1190/tle36030215.1.

CHEN, Y. & WU, W. **Mapping mineral prospectivity using an extreme learning machine regression**. 2016. Ore Geology Reviews. 80. 10.1016/j.oregeorev.2016.06.033.

CIAMPALINI, A.; GARFAGNOLI, F.; ANTONIELLI, B.; MORETTI, S.; RIGHINI, G., 2013. **Remote sensing techniques using Landsat ETM+ applied to the detection of iron ore deposits in Western Africa**. Arabian Journal of Geosciences. 10.1007/s12517-012-0725-0.

CLEVELAND, S. **Robust Locally Weighted Regression and Smoothing Scatterplots**. *Journal of the American Statistical Association*. 74 (368): 829–836. 1979.

COULTER, D.; ZHOU, X.; WICKERT, L.M; HARRIS, P.D., 2017. **Advances in Spectral Geology and Remote Sensing: 2008 – 2017**. In “Proceedings of Exploration 17: Sixth Decennial International Conference on Mineral Exploration” Toronto, ON, Canada.

CUNHA, J. C.; SILVA, R. W. S.; MORAES, A. M. V. de. **Minério de ferro do norte da Bahia, áreas dos blocos Casa Nova-Sento Sé e Remanso-Pilão Arcado: caracterização, ambiente geológico, histórico de exploração e potencial**. sumário técnico para o edital da concorrência pública nº 009/2008. Salvador: CBPM, 2008.

DALTON DE SOUZA, J.; FERNANDES, F. J.; GUIMARÃES, J. T.; LOPES, J. N. 1979. **Projeto Colomi; geologia da região do Médio São Francisco**, Salvador, CPRM. convênio DNPM/CPRM. 3v.

DEB, M.; KAUR, G., 2008. **Earth processes and resources: Metallogeny**. In book: Earth processes and resources: Metallogeny. pp.1-49

ELSEVIER. — **How Scopus Works—Scopus**—Elsevier Solutions. Available online: <<https://www.elsevier.com/solutions/scopus/how-scopus-works/content>>. Acesso em 29 out. 2020.

FEIZI, F.; MANSOURI, E., 2013. **Introducing the Iron Potential Zones Using Remote Sensing Studies in South of Qom Province, Iran**, Open Journal of Geology, Vol. 3 No. 4, 2013, pp. 278-286. doi: 10.4236/ojg.2013.34032.

FORD, A., HART, C., (2013). **Mineral potential mapping in frontier regions: A Mongolian case study**, Ore Geology Reviews, Vol. 51, pp. 15-26, I. doi: 10.1016/j.oregeorev.2012.11.002.

GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D., & MOORE, R. 2017. **Google Earth Engine: Planetary-scale geospatial analysis for everyone**. **Remote Sensing of Environment**.

GROSS, G. A. **A classification of iron formations based on depositional environments**. Canadian Mineralogist, Ottawa, v. 18, n. 2, p. 215-222, May 1980.

GUSENBAUER, M. 2019. **Google Scholar to overshadow them all? Comparing the sizes of 12 academic search engines and bibliographic databases**. Scientometrics 118, 177–214 (2019). <https://doi.org/10.1007/s11192-018-2958-5>

HARVEY, A. & FOTOPOULOS, G., 2016. **Geological mapping using Machine Learning algorithms**. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLI-B8. 423-430. 10.5194/isprs-archives-XLI-B8-423-2016.

HILL, E. J., N. H. OLIVER, L. FISHER, J. S. CLEVERLEY, AND M. J. NUGUS, 2014, **Using geochemical proxies to model nuggety gold deposits: An example from Sunrise Dam, Western Australia**: Journal of Geochemical Exploration, 145, 12–24.

HO, T. K. 1995. **Random Decision Forests**. Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, QC, 14–16 August 1995. pp. 278–282.

HOJAT, S.; EHSAN, F.; DIETMAR, M.R.; ROHITASH, C., 2021. **A review of machine learning in processing remote data for mineral exploration**. Remote Sensing of Environment. Open Access. Volume 268January 2022 Article number 112750

HRONSKY, J. GROVES, D. **Science of targeting: Definition, strategies, targeting and performance measurement**. Australian Journal of Earth Sciences - AUST J EARTH SCI. 55. 3-12. 10.1080/08120090701581356. 2008.

HUNT, G.R.; SALISBURY, J.W.; LENHOFF, C.J. **Visible and Near-infrared Spectra of Minerals and Rocks: III. Oxides and Hydroxides**. Modern Geology, 1971, 2, pp. 195- 205.

IBGE. **Manual Técnico da Vegetação Brasileira**. 2a ed. Rio de Janeiro: IBGE. Disponível em: <<http://www.ibge.gov.br/home/geociencias/recursosnaturais/>>, 2012.

IBGE. **Mapa de Biomas do Brasil. Primeira Aproximação**. Escala 1:5.000.000. Rio de Janeiro: IBGE. Disponível em: <http://www.terrabrasilis.org.br/ecotecadigital/index.php/>, 2004.

JOWITT, S.M., 2020. **COVID-19 and the Global Mining Industry**. SEG Discovery 2020; (122): 33–41. doi: <https://doi.org/10.5382/SEGnews.2020-122fea-02>

KUZVART, M. & BÖHMER, M. 1986. **Prospecting and exploration of mineral deposits**. 2a. ed., Developments in economic geology vol. 21, Elsevier Ed., (N.Y.) USA, 508 pp

LANFRANCHI, R.; CERQUEIRA P.C.S.; FRANCA-ROCHA, W. **Application of remote sensing and reflectance spectroscopy to explore iron-enriched domains in the north region of the intracontinental sector of the Araçuaí West Congo Orogen**. ORE GEOLOGY REVIEWS, v. 127, p. 103916, 2020

LIU, L.; CHEN, J.; ZHOU, T.; ZAHNG, Y.; LI, M., 2021. **The new application of geometallurgy in department of gold and critical metals studies**. Yanshi Xuebao/Acta Petrologica Sinica, Volume 37, Issue 9, Pages 2691 – 2704.

LOBO, F.L; SOUZA-FILHO, P.W.M; NOVO, E.M.L.M; CARLOS, F.M; BARBOSA, C.C.F. **Mapping mining areas in the Brazilian Amazon using M SI/ Sentinel-2 Imagery (2017)**. Remote Sens. 2018, 10 (8), 1178.

MAJID. G; NARGES, Y.; KONARI, B.M., 2018. **Porphyry Copper Deposits of Iran**. Publisher: Tarbiat Modares University. Dec 2018, ISBN: 978.600.7589.69.4

MARZIYEH, M.M.; OSANLOO, M., 2015. **Chaos in iron ore price prediction.** Conference: The Southern African Institute of Mining and Metallurgy MPES 2015 – Smart Innovation in MiningAt: Sandton Convention Centre, Johannesburg, South Africa.

MASEK, J.G; WULDER, M.A.; MARKHAM, B.; MCCORKEL, J.; CRAWFORD, C.J.; STOREY, J.; JENSTROM, D.T., 2020. **Landsat 9: Empowering open science and applications through continuity.** Remote Sensing of Environment, V. 248, 111968, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2020.111968>.

MENESES, P.R; ALMEIDA, T. 2012. **Introdução ao processamento de imagens de sensoriamento remoto.** UNB. Brasília, DF. 276p.

OURHZIF, Z.; AHMED, A.; AB, A.; FATIHA, H., 2019. **Lithological mapping using landsat 8 oli and aster multispectral data in imini-ounilla district south high atlas of marrakech.** ISPRS Journal of Photogrammetry and Remote Sensing. XLII. 1255-1262. 10.5194/isprs-archives-XLII-2-W13-1255-2019.

PEREIRA, A.B., **Mata Atlântica: uma abordagem geográfica.** Nucleus, v.6, n.1, p. 27-52, (2009).

RAJESH, H.M., 2004, **Application of remote sensing and GIS in mineral resource mapping: an overview.** Queensland, Australia. Journal of Mineralogical and Petrological Sciences, v. 99, pp 83-103 Jun/2004.

RIBEIRO, A.F., **Potencialidade do minério de ferro no estado da Bahia.** Salvador, Bahia. 102 p.: il. color. Série publicações especiais; 20, ISBN 978-85-85680-61-9. Companhia Baiana de Pesquisa mineral, CBPM, 2017.

SAFIROVA, H., 2018. **The Mineral Industry of Russia.** USGS Minerals Yearbook. Advance Release, Chapter 19, p.19.

SAIBI, HAKIM & BERSI, MOHAND & MIA, MD & SAADI, NUREDDIN & AL BLOUSHI, KHALID & AVAKIAN, ROBERT. 2018. **Applications of Remote Sensing in Geoscience.** 10.5772/intechopen.75995.

SANO, S.M., ALMEIDA, S.P. & RIBEIRO, J.F. (eds) (2008). **Cerrado: ecologia e flora.** Brasília: Embrapa Informação Tecnológica; Planaltina: Embrapa Cerrados. 2 vol.,

SANTANA, A.J. et al. **Projeto cadastramento de ocorrências minerais do estado da Bahia:** área II - Juazeiro. Salvador: SME; CPM, v. 2. 1974.

SANTANA, M.; MARIANO-NETO, E.; VASCONCELOS, R.; DODONOV, P.; MEDEIROS, J. 2021. **Mapping the research history, collaborations, and trends of remote sensing in fire ecology.** Scientometrics. 126. 10.1007/s11192-020-03805-x.

SDE, Secretaria de Desenvolvimento econômico da Bahia, Ministério de Minas e Energia (MME). **Sumário Mineral – novembro de 2020.** Acesso em http://www.sde.ba.gov.br/wp-content/uploads/2022/11/Sum%C3%A1rio_Mineral-NOVEMBRO-com-dados-de-OUTUBRO-2022.pdf.

SILVA, A.; DUCART, D.; TOLEDO, B.; ASSIS, L., 2016. **Mapping iron oxides with Landsat-8/OLI and EO-1/Hyperion imagery from the Serra Norte iron deposits in the Carajás**

Mineral Province, Brazil. Brazilian Journal of Geology. 46. 331-349. 10.1590/2317-4889201620160023

SILVA, A.B. **Sistemas de Informações Geo-referenciadas: Conceitos e fundamentos.** Livro texto , 1^a Ed 2003, UNICAMP, Campinas, SP, 236p.

SONG, Y; WANG, N.; YU, A., 2019. **Temporal and spatial evolution of global iron ore supply-demand and trade structure.** Resources Policy, V.64, 101506,ISSN 0301-4207,<https://doi.org/10.1016/j.resourpol.2019.101506>.

SHIRAZI, A.; HEZARKHANI, A.; SHIRAZY, A., 2018. **Remote Sensing Studies for Mapping of Iron Oxide Regions, South of Kerman, IRAN.** International Journal of Science and Engineering Applications. 7. 045-051. 10.7753/IJSEA0704.1002.

SOARES FILHO, A. 2015. **Análise de processos de transformação da paisagem com base em espectroscopia de reflectância e sensoriamento remoto multiespectral: Estudo de caso no núcleo de Gilbués, Piauí, Brasil.** Tese de Doutorado, UNICAMP, Campinas, SP, 161p.

SOUZA, J. D. de et al. **Projeto Colomi: relatório final: geologia e prospecção geoquímica da região de Remanso-Sento Sé.** Salvador: CPRM, 1979. 10 v.

SOUZA FILHO, C.R.; TAPIA CALLE, C.H.; CROSTA, A.P.; XAVIER, R.P. **Infrared Spectroscopy and ASTER imagery Analysis of Hidrothermal alteration Zones at the Quellaveco Porphyry-Copper deposit, Southern Peru.** In: Ann. Conf. of Am. Soc. for Photog. and Rem. Sens. (ASPRS), Proceedings, 2003, pp. 1-12.

TEIXEIRA, L., **O Complexo Caraíba e a Suíte São José do Jacuípe no cinturão salvador-curaçá (bahia, brasil): petrologia, geoquímica e potencial metalogenético.** Universidade Federal da Bahia. Tese de doutorado, p. 208. 1997

TEIXEIRA, J., SILVA, G., MISI, A., CRUZ, S., SILVA SÁ, J., **Geotectonic setting and metallogeny of the northern São Francisco craton, Bahia, Brazil.** Journal of South American Earth Sciences, 2010, 30(2), pp. 71–83

TEIXEIRA, N.; GANADE, C.; MATOS, F.; CAMPOS, L.; NAVES, M.C., 2015. **Alkaline porphyry copper deposits and iocg – what is the link.**

VAN DER MEER, F.D.; VAN DER WERFF, H.M.A. **Sentinel-2 for Mapping Iron Absorption Feature Parameters.** Remote Sensing of Environment, 2015, 7, 12635–12653.

VAN DER WERFF, H., HEWSON, R. **Using Sentinel-2 MSI for mapping iron oxide minerals on a continental and global scale.** Authorea. January 15, 2020.

VASCONCELOS, R.N.; LIMA, A.T.C.; LENTINI, C.A.D.; MIRANDA, G.V.; MENDONÇA, L.F.; SILVA, M.A.; CAMBUÍ, E.C.B.; LOPES, J.M.; PORSANI, M.J., 2020. **Oil Spill Detection and Mapping: A 50-Year Bibliometric Analysis.** Remote Sens. 2020, 12, 3647. <https://doi.org/10.3390/rs1221364>

WU, C.; LI, X.; CHEN, W.; LI, X., 2018. **A Review of Geological Applications of High-Spatial-Resolution Remote Sensing Data.** 10.20944/preprints201811.0162.v1.

YE, Z.; WANG, G.; LI, M.; HAN, S., 2018. **Automated Classification Analysis of Geological Structures Based on Images Data and Deep Learning Model**. Applied Sciences. 8. 2493. 10.3390/app8122493.

ZHANG, Y.; GANG, W.; MINGCHAO, L.; SHUAI, H., 2018. **Automated Classification Analysis of Geological Structures Based on Images Data and Deep Learning Model**. Applied Sciences. 8. 2493. 10.3390/app8122493.

ANEXO 2 – TABELA DE COMPARAÇÃO DAS ASSINATURAS ESPECTRAIS PELO SAM

alvo	zona	classe	corr SAM hematita alto teor	corr SAM hematita baixo teor	corr SAM quartzo ferruginoso	corr SAM itabirito alto teor	corr SAM itabirito baixo teor	Media corr nova classe	classe
caetite	cava	1	91%	88%	85%	93%	94%	90% minério baixo Fe itabirito	1
moco	cava	2	93%	92%	86%	84%	90%	88% solo alto Fe hematita	2
moco	cava	1	93%	84%	88%	87%	87%	88% minério alto Fe hematita	2
caetite	cava	2	86%	88%	82%	83%	85%	85% solo baixo Fe hematita	2
moco	10km	2	88%	83%	81%	76%	85%	82% solo alto Fe hematita	3
caetite	cava	3	48%	45%	39%	51%	46%	46% veg baixo Fe itabirito	7
moco	cava	4	80%	76%	74%	70%	76%	76% misto baixo Fe itabirito	4
caetite	cava	4	79%	73%	70%	70%	86%	76% misto baixo Fe itabirito	4
caetite	100m	2	72%	74%	66%	67%	75%	71% solo baixo Fe itabirito	3
caetite	100m	3	48%	46%	45%	38%	45%	44% veg baixo Fe hematita	7
moco	100m	2	72%	70%	75%	62%	74%	71% solo Fe quartzo	3
caetite	100m	4	62%	59%	58%	52%	64%	55% misto baixo Fe hematita	5
moco	500m	2	71%	68%	73%	61%	74%	69% solo baixo Fe itabirito	3
moco	200m	4	67%	65%	71%	57%	70%	66% misto Fe quartzo	5
moco	100m	4	68%	67%	59%	59%	70%	66% misto baixo Fe itabirito	5
moco	10km	4	68%	64%	62%	58%	73%	65% misto baixo Fe itabirito	5
caetite	200m	2	67%	63%	62%	57%	69%	64% solo baixo Fe itabirito	3
moco	cava	3	66%	64%	62%	56%	63%	62% veg baixo Fe hematita	6
moco	500m	4	64%	62%	60%	55%	67%	62% misto baixo Fe itabirito	5
caetite	200m	3	52%	49%	48%	42%	55%	49% veg baixo Fe itabirito	7
moco	200m	2	63%	60%	58%	53%	65%	60% solo baixo Fe itabirito	3
caetite	200m	4	61%	59%	58%	52%	64%	59% misto baixo Fe itabirito	5
caetite	500m	2	84%	82%	78%	75%	83%	80% solo alto Fe hematita	3
moco	200m	3	61%	59%	57%	51%	64%	58% veg baixo Fe itabirito	6
moco	100m	3	61%	58%	57%	51%	64%	58% veg baixo Fe itabirito	6
moco	10km	3	58%	55%	53%	48%	62%	55% veg baixo Fe itabirito	6
caetite	500m	3	47%	45%	53%	37%	51%	47% veg Fe quartzo	7
moco	500m	3	51%	57%	48%	42%	54%	50% veg baixo Fe hematita	7
caetite	500m	4	63%	60%	53%	59%	60%	53% misto Fe quartzo	5
caetite	10km	2	76%	71%	67%	66%	81%	72% solo baixo Fe itabirito	3
caetite	10km	3	54%	51%	44%	57%	53%	53% veg Fe quartzo	7
caetite	10km	4	73%	69%	66%	63%	78%	70% misto baixo Fe itabirito	4

Capítulo IV

4.1 CONSIDERAÇÕES E RECOMENDAÇÕES FINAIS

Com base nas questões norteadoras que orientaram este estudo e o objetivo proposto, que era identificar áreas com relevante potencial de prospecção para ferro, utilizando quadros conceituais e analíticos para indicadores diagnósticos e métodos numéricos baseados em conjuntos de dados geoespaciais, são feitas as seguintes recomendações e considerações.

Sobre o artigo 1: “APLICAÇÕES GEOLÓGICAS DE SENSORIAMENTO REMOTO NA PESQUISA DO POTENCIAL MINERAL PARA FERRO: UMA ANÁLISE BIBLIOMÉTRICA.” – Este estudo conclui-se reforçando a ideia de que o bibliometria se constitui como uma ferramenta relevante para os estudos da pesquisa mineral, sobretudo para permitir uma contextualização de sua evolução como ciência. A análise das redes de palavras-chave permitiu identificar tendências existentes, padrões relacionais e, sendo assim, foi um dado relevante para o prosseguimento desta pesquisa, sobretudo na delimitação do universo de análise que esse trabalho seguirá. A utilização de métodos híbridos, embora complexa e ainda limitada na literatura revisada, parecem promissores na melhor investigação desse campo de atuação.

Sobre o artigo 2: “APLICAÇÕES GEOLÓGICAS DE SENSORIAMENTO REMOTO NA PESQUISA DO POTENCIAL MINERAL PARA FERRO: MAPEAMENTO DA POTENCIALIDADE NO ESTADO DA BAHIA” – Este trabalho possibilitou analisar os resultados obtidos por processamentos digitais de imagem em nuvem, que foi importante para demonstrar o potencial de utilizar técnicas sofisticadas de sensoriamento remoto para produzir dados em larga escala. O uso conjunto dos classificadores SAM e RF permitiu a caracterização por imagem utilizando diferentes amostras geoespaciais referentes a de tipos de minérios, solos e classes de vegetação com alto e baixo teor de ferro. A espetrorradiometria de reflectância provou ser uma ferramenta útil para ajudar a discriminar entre diferentes classes ao analisar curvas de assinatura espectral.