

**INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA DE GOIÁS
CAMPUS GOIÂNIA
DEPARTAMENTO ACADÊMICO DA ÁREA III
COORDENAÇÃO DE ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA**

LARISSA CRISTINA RODRIGUES LIMA

TRABALHO DE CONCLUSÃO DE CURSO

**MAPEAMENTO DAS ÁREAS DE GARIMPO EM TERRAS
INDÍGENAS MUNDURUKU UTILIZANDO MODELO
BASEADO EM CONHECIMENTO E INTEGRAÇÃO
MULTISENsoRES**

Goiânia, GO

JUNHO/2022

**TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO
NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG**

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| ☐ Tese | ☐ Artigo Científico |
| ☐ Dissertação | ☐ Capítulo de Livro |
| ☐ Monografia – Especialização | ☐ Livro |
| ☒ TCC - Graduação | ☐ Trabalho Apresentado em Evento |
| ☐ Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Larissa Cristina Rodrigues Lima

Matrícula: 20161011190253

Título do Trabalho: Mapeamento das áreas de garimpo em Terras Indígenas Munduruku utilizando modelo baseado em conhecimento e integração multisensores.

Autorização - Marque uma das opções

1. ☒ Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
2. ☐ Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ____/____/____ (Embargo);
3. ☐ Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:


- ☐ O documento está sujeito a registro de patente.
☐ O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
☐ Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- i. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- ii. obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- iii. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

Goiânia-GO, 26/08/2022.



Assinatura do Autor e/ou Detentor dos Direitos Autorais

Instituto Federal de Educação, Ciência e Tecnologia de Goiás
LARISSA CRISTINA RODRIGUES LIMA

**MAPEAMENTO DAS ÁREAS DE GARIMPO EM TERRAS
INDÍGENAS MUNDURUKU UTILIZANDO MODELO
BASEADO EM CONHECIMENTO E INTEGRAÇÃO
MULTISENORES**

Trabalho de Conclusão de Curso apresentado à
Coordenação do Curso de Bacharelado em Engenharia
Cartográfica e de Agrimensura como requisito parcial para
obtenção do título de Bacharel em Engenharia Cartográfica
e de Agrimensura.

Orientador: Prof. Dr. Giovanni de Araujo Boggione

Goiânia, GO
JUNHO/2022

L732m Lima, Larissa Cristina Rodrigues.

Mapeamento das áreas de garimpo em terras indígenas munduruku utilizando modelo baseado em conhecimento e integração multisensores / Larissa Cristina Rodrigues Lima. – Goiânia: Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2022.
116f.

Orientação: Prof. Dr. Giovanni de Araújo Boggione.

TCC (Trabalho de Conclusão de Curso) – Curso de Bacharelado em Engenharia Cartográfica e de Agrimensura, Coordenação de Engenharia Cartográfica e de Agrimensura, Departamento da Área Acadêmica III, Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

1. Processamento digital de imagens. 2. Garimpo. 3. Índios munduruku. I. Boggione, Giovanni de Araújo (orientação). II. Instituto Federal de Educação, Ciência e Tecnologia de Goiás. III. Título.

CDD 621.367 8

Ficha catalográfica elaborada pela bibliotecária Lana Cristina Dias Oliveira CRB1/ 2.631
Biblioteca Professor Jorge Félix de Souza,
Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Câmpus Goiânia.


TERMO DE APROVAÇÃO

Larissa Cristina Rodrigues Lima

MAPEAMENTO DAS ÁREAS DE GARIMPO EM TERRAS INDÍGENAS MUNDURUCU UTILIZANDO MODELO BASEADO EM CONHECIMENTO E INTEGRAÇÃO MULTISENORES

Trabalho de Conclusão de Curso apresentado à Coordenação de Engenharia Cartográfica e de Agrimensura, do Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Câmpus Goiânia, como parte dos requisitos necessários para a obtenção do título de Bacharelado em Engenharia Cartográfica e de Agrimensura.

Aprovado em, 30 de junho de 2022.


Prof. Dr. Giovanni de Araújo Boggione (IFG)
(Orientador)


Prof. Dr. João Paulo Magna Junior (IFG)
(Membro da Banca Examinadora)


Profa. Ma. Elaine Reis Costa Lima (IFG)
(Membro da Banca Examinadora)

GOIÂNIA, GO

2022

AGRADECIMENTOS

Primeiramente, aos meus pais que me apoiaram desde o princípio, não há palavras e ações que demonstrem tamanha gratidão que tenho em tê-los em minha vida. Sem vocês essas realizações não seriam possíveis. Obrigada por acreditarem em mim.

Aos meus familiares que sempre me apoiaram e incentivaram, em especial aos meus avós que tanto me ensinaram, Marieta (*in memorian*), Zequinha (*in memorian*), Tereza (*in memorian*) e Clauduarte(*in memorian*), e minha querida madrinha Franciane e meu amado irmão Henrique. Aos meus sobrinhos que tanto amo, que são a minha base.

Ao Prof. Dr. Giovanni de Araujo Boggione pelo excelente trabalho como orientador, e por todas as trocas de conhecimentos nas disciplinas, iniciação científica e, principalmente, neste trabalho. Muito obrigada por toda a dedicação e paciência. Você é incrível.

A Mestra Marina Alberti Macedo por todo o apoio durante o curso. Suas palavras e conversas foram de grande ajuda. Nunca esquecerei de suas palavras nos momentos de aflição, como por exemplo: Há males que vem para o bem. Só tenho a agradecer, pois com toda certeza estou colhendo os bons frutos das minhas escolhas que foram influenciadas por você.

Aos amigos que fiz nesta instituição, em especial a Angela Gabrielly, João Pedro e Marlísia, que tanto me incentivaram para nunca desistir de meus sonhos. Vocês foram e são importantes em minha jornada. Também as amigas Danielly e Jennifer que sempre estão me apoiando e são minha família em Goiânia. E a querida Paula que me acompanhou e apoiou nessa caminhada durante a disciplina de Trabalho de Conclusão de Curso.

A minha querida noiva, Angélica Junior, que tanto fez e faz por mim, as noites em claro me apoiando e me dando forças para vencer as dificuldades durante a vida. Essa conquista também é sua, meu amor.

Por fim, agradeço ao Instituto Federal de Goiás que forneceu a estrutura e o corpo docente necessário para a minha formação. Também agradeço aos membros da banca por terem aceitado o convite e pelas contribuições deste trabalho.

“A soul in tension that's learning to fly”

(Learning to fly – Pink Floyd)

RESUMO

As consequências da atividade garimpeira na Amazônia, que é responsável por um terço do extrativismo mineral brasileiro, ocasionam uma transformação da paisagem e da natureza, bem como diversos problemas sociais. Considerando esta problemática, este trabalho propõe um modelo de classificação baseado em conhecimento que melhor corresponde à identificação e mapeamento de áreas de garimpo, particularmente em terras indígenas, e, por consequência, verifica a expansão dessas áreas nos anos de 2010, 2016, 2018 e 2021. As Terras Indígenas Munduruku estão entre as terras que mais sofrem com as pressões da exploração mineral ilegal e pelas especulações de grandes empresas mineradoras. Para a análise temporal foram utilizadas imagens dos satélites Landsat 5, Landsat 8 e CBERS 04A caracterizando, dessa forma, um estudo multisensor. Como parte da modelagem foram testados os algoritmos de classificação supervisionada *Random Forest*, *Support Vector Machine* e *Geographic Object-Based Image Analysis*, e índices espectrais como Índice de Vegetação de Diferença Normalizada (NDVI) e Índice de Água Diferença Normalizada (NDWI). Os resultados encontrados neste trabalho apontam para um crescimento considerável das áreas de garimpo. Em comparação ao ano 2000, em 2010 não havia sinais de novas áreas de atividade garimpeira, já no ano de 2016, foi mapeada uma área de mais de 700 hectares transformados, o que corresponde a um crescimento de mais de 15 vezes a área de 2010. De 2016 para 2018, houve um crescimento de 66%. De 2018 para 2021, o crescimento foi de 525%. Considerando de 2016 para 2021, o crescimento foi de 936,6%, ou seja, em cinco anos as áreas contendo atividade garimpeira na região tiveram um aumento de quase dez vezes.

Palavras-chave

Processamento digital de imagens, sensoriamento remoto, garimpo, Terra Indígena, algoritmos de classificação, Análise de Imagens Baseada em Objetos Geográficos (GEOBIA)

ABSTRACT

The consequences of mining activity in the Amazon, which is responsible for a third of Brazilian mineral extraction, cause a transformation of the landscape and nature, as well as several social problems. Considering this problem, this work proposes a knowledge-based classification model that best corresponds to the identification and mapping of mining areas, particularly in indigenous lands, and, consequently, verifies the expansion of these areas in the years 2010, 2016, 2018 and 2021. The Munduruku Indigenous Lands are among the lands that most suffer from the pressures of illegal mineral exploration and speculation by large mining companies. For the temporal analysis, images from the satellites Landsat 5, Landsat 8 and CBERS 04A were used, thus characterizing a multisensor study. As part of the modeling, the supervised classification algorithms Random Forest, Support Vector Machine and Geographic Object-Based Image Analysis were tested, and spectral indices such as Normalized Difference Vegetation Index (NDVI) and Normalized Difference Water Index (NDWI). The results found in this work point to a considerable growth in the mining areas. Compared to the year 2000, in 2010 there were no signs of new areas of mining activity, in 2016, an area of more than 700 transformed hectares was mapped, which corresponds to a growth of more than 15 times the area of 2010. From 2016 to 2018, there was a growth of 66%. From 2018 to 2021, the growth was 525%. Considering from 2016 to 2021, the growth was 936.6%, that is, in five years the areas containing mining activity in the region had an increase of almost ten times.

Keywords

Digital image processing, remote sensing, mining, indigenous land, classification algorithms, Geographic Object-Based Image Analysis (GEOBIA)

LISTA DE FIGURAS

Figura 1 - Componentes do sistema geoAIDA.....	28
Figura 2 - Representação do algoritmo Randon Forest.	29
Figura 3 - Exemplo da aplicação da técnica de Kernel.....	30
Figura 4 - Exemplo da aplicação do hiperplano linear.	30
Figura 5 - Processo da análise baseada em objetos geográficos.....	31
Figura 6 - Matriz de confusão.....	35
Figura 7 - Localização da área de estudo - Terra Indígena Munduruku.....	39
Figura 8 - Fluxograma metodológico.	42
Figura 9 - Fluxograma metodológico da etapa do pré-processamento.....	43
Figura 10 - Fluxograma metodológico da etapa da geração de dados auxiliares.	46
Figura 11 - Fluxograma metodológico da etapa de análise e processamento dos dados secundários.	50
Figura 12 – Imagem Landsat 5/TM para o ano de 2010: a) sem correção atmosférica e b) com correção atmosférica.....	56
Figura 13 - Mapa do índice NDVI para o ano de 2010.	58
Figura 14 - Mapa do índice NDVI para o ano de 2016.	59
Figura 15 - Mapa do índice NDVI para o ano de 2018.	60
Figura 16 - Mapa do índice NDVI para o ano de 2021.	61
Figura 17 - Mapa do índice NDWI para o ano de 2010.	62
Figura 18 - Mapa do índice NDWI para o ano de 2016.	63
Figura 19 - Mapa do índice NDWI para o ano de 2018.	64
Figura 20 - Mapa do índice NDWI para o ano de 2021.	65
Figura 21 - Classificação GEOBIA para o ano de 2010.....	67
Figura 22 - Classificação GEOBIA para o ano de 2016.....	68
Figura 23 - Classificação GEOBIA para o ano de 2018.....	69
Figura 24 - Classificação GEOBIA para o ano de 2021.....	70
Figura 25 - Classificação Random Forest para o ano de 2010.	74
Figura 26 - Classificação Random Forest para o ano de 2016.	75
Figura 27 - Classificação Random Forest para o ano de 2018.	76

Figura 28 - Classificação Random Forest para o ano de 2021.	77
Figura 29 - Classificação Support Vector Machine para o ano de 2010.	80
Figura 30 - Classificação Support Vector Machine para o ano de 2016.	81
Figura 31 - Classificação Support Vector Machine para o ano de 2018.	82
Figura 32 - Classificação Support Vector Machine para o ano de 2021.	83
Figura 33 - Comparação entre o Google Earth e o resultado do Modelo 01 para as regiões A e B.	85
Figura 34 - Comparação entre o Google Earth e o resultado do Modelo 02 para as regiões A e B.	86
Figura 35 - Comparação entre o Google Earth e o resultado do Modelo 03 para as regiões A e B.	87
Figura 36 - Comparação entre o Google Earth e o resultado do Modelo 04 para as regiões A e B.	88
Figura 37 - Comparação entre o Google Earth e o resultado do Modelo 05 para as regiões A e B.	89
Figura 38 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2010.	93
Figura 39 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2016.	94
Figura 40 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2018.	95
Figura 41 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2021.	96
Figura 42 - Mapeamento das áreas de garimpo nos anos de 2010,2016,2018 e 2021..	98
Figura 43 - Mapeamento das áreas de garimpo nos anos de 2010.	99
Figura 44 - Mapeamento das áreas de garimpo nos anos de 2016.	100
Figura 45 - Mapeamento das áreas de garimpo nos anos de 2018.	101
Figura 46 - Mapeamento das áreas de garimpo nos anos de 2021	102
Figura 47 - Áreas de garimpo (hectare/ano).	103

LISTA DE QUADROS

Quadro 1 - Caracterização das câmeras imageadoras do satélite CBERS 04A.	25
Quadro 2 - Características dos sensores a bordo do satélite Landsat 5.	25
Quadro 3 - Características dos sensores a bordo do satélite Landsat 8.	26
Quadro 4 - Descrição dos atributos espaciais.	32
Quadro 5 – Classes do coeficiente Kappa.	35
Quadro 6 - Índices espectrais utilizados no estudo.	46
Quadro 7 - Quantidade de amostras por classe.	47
Quadro 8 - Descrição das classes de uso e cobertura do solo.	47
Quadro 9 - Parâmetros utilizados para a segmentação de imagens.	48
Quadro 10 - Quantidade de amostras por classe.	48
Quadro 11 - Área de garimpo em hectares para cada ano.	103

LISTA DE TABELAS

Tabela 1 - Bandas utilizadas para o empilhamento.	44
Tabela 2 – Dados e regras utilizadas no Modelo 01.	51
Tabela 3 – Dados e regras utilizadas no Modelo 02.	51
Tabela 4 - Dados e regras utilizadas no Modelo 03.	52
Tabela 5 – Dados e regras utilizadas no Modelo 05.	52
Tabela 6 - Matriz de confusão do ano de 2021.	71
Tabela 7 - Matriz de confusão do ano de 2010.	71
Tabela 8 - Matriz de confusão do ano de 2016.	72
Tabela 9 - Matriz de confusão do ano de 2018.	72
Tabela 10 - Matriz de confusão do ano de 2021.	72
Tabela 11 – Resultado do índice Kappa do algoritmo Random Forest.	73
Tabela 12 - Matriz de confusão do ano de 2010.	78
Tabela 13 - Matriz de confusão do ano de 2016.	78
Tabela 14 - Matriz de confusão do ano de 2018.	78
Tabela 15 - Matriz de confusão do ano de 2021.	79
Tabela 16 - Resultado do índice Kappa do algoritmo Support Vector Machine.	79
Tabela 17 - Matriz de confusão do modelo 1.	90
Tabela 18 - Matriz de confusão do modelo 2.	90
Tabela 19 - Matriz de confusão do modelo 3.	91
Tabela 20 - Matriz de confusão do modelo 4.	91
Tabela 21 - Matriz de confusão do modelo 5.	92
Tabela 22 - Resultado do índice Kappa dos modelos.	92

LISTA DE EQUAÇÕES

1 Equação do cálculo do índice kappa.....	35
2 Equação do cálculo da Exatidão Global (Po).....	36

LISTA DE ABREVIATURAS E SIGLAS

AIDA	<i>Automatic Image Data Analyser</i>
ANM	Agência Nacional de Mineração
ATCOR	<i>Atmospheric Correction</i>
EPSG	<i>European Petroleum Survey Group</i>
GEOBIA	<i>Geographic Object-Based Image Analysis</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
LDCM	<i>Landsat Data Continuity Mission</i>
MSS	<i>Multispectral Scanner System</i>
MODTRAN	<i>Moderate resolution atmospheric Transmission</i>
MUX	Câmera Multiespectral
ND	Níveis Digitais
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
OLI	<i>Operational Land Imager</i>
PDI	Processamento Digital de Imagens
PRODES	Projeto de Monitoramento do Desmatamento na Amazônia Legal
RBF	<i>Radial Basis Function</i>
RCID	Relatório Circunstanciado de Identificação e Delimitação

RF	<i>Random Forest</i>
SIGs	Sistema de Informações Geográficas
SVM	<i>Support Vector Machine</i>
T.I.	Terra Indígena
TCC	Trabalho de Conclusão de Curso
TIRS	<i>Thermal Infrared Sensor</i>
TM	<i>Thematic Mapper</i>
USGS	<i>United States Geological Survey</i>
WFI	<i>Wide Field Image</i>
WPM	<i>Wide Panchromatic and Multispectral Camera</i>

SUMÁRIO

1. INTRODUÇÃO	17
2. OBJETIVOS	18
3. REVISÃO DA LITERATURA	19
3.1 ATIVIDADE GARIMPEIRA NO BRASIL	19
3.2 ATIVIDADE GARIMPEIRA NA AMAZÔNIA	20
3.3 ATIVIDADE GARIMPEIRA EM TERRAS INDÍGENAS	21
3.4 ATIVIDADE GARIMPEIRA EM TERRAS INDÍGENAS MUNDURUKU	22
3.5 GEOTECNOLOGIAS NO MEIO AMBIENTE	23
3.6 SATÉLITES E SENSORES	24
3.6.1 CBERS 04A	24
3.6.2 Landsat 5	25
3.6.3 Landsat 8	26
3.7 TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS	27
3.7.1 Classificação supervisionada	28
3.7.1.1 <i>Random Forest</i>	28
3.7.1.2 <i>Support Vector Machine</i>	29
3.7.1.3 <i>Geographic Object-Based Image Analysis (GEOBIA)</i>	31
3.7.1.4 <i>Validação do processo de classificação</i>	34
3.7.2 Índices espectrais	36
4. METODOLOGIA	38
4.1 Localização e Caracterização da Área de Estudo	38
4.2 Materiais e softwares	41
4.3 Procedimentos Metodológicos	41
4.3.1 Coleta de Dados	42
4.3.2 Pré-processamento dos dados ópticos	43
4.3.5 Geração de dados auxiliares	45

4.3.5.1	<i>Amostras de treinamento e validação</i>	47
4.3.5.2	<i>Classificação de imagens</i>	48
4.3.5.3	<i>Validação</i>	49
4.3.5.4	<i>Pós-Classificação</i>	49
4.3.6	Análise e processamento dos dados secundários	49
4.3.7	Classificação baseada em conhecimento	50
5.	RESULTADOS	54
5.1	Pré-processamento de imagens	54
5.2	GERAÇÃO DE DADOS AUXILIARES	57
5.2.1	Índices espectrais	57
5.2.2	Classificação de imagens	66
5.2.2.1	<i>Classificação GEOBIA</i>	66
5.2.2.2	<i>Classificação RF</i>	71
5.2.2.3	<i>Classificação SVM</i>	78
5.3	CLASSIFICAÇÃO BASEADA EM CONHECIMENTO	84
5.4	MAPEAMENTO DAS ÁREAS DE GARIMPO	97
6.	DISCUSSÕES	104
7.	CONCLUSÕES	105
	REFERÊNCIAS	106

1. INTRODUÇÃO

No Brasil, a garimpagem teve a importância de marcar diversos períodos da história e consagrar o país como um dos maiores produtores de matéria-prima mineral (FURTADO, 2020). Os garimpos começaram a fazer parte da região do bioma Amazônico, como os estados do Amapá, Pará e Acre. O início mais expressivo da garimpagem na Amazônia data de 1958, quando foram encontradas as primeiras jazidas de ouro na região do Tapajós (BRITO; BRUSEKE; MATHIS, 1997).

As consequências da atividade garimpeira na Amazônia, enquanto atividade extrativa mineral, ocasiona uma transformação da paisagem e da natureza, bem como diversos problemas sociais. Os conflitos sociais decorrentes da invasão de terras indígenas e os impactos ambientais são evidentes. Dentre eles, desmatamento, assoreamento e a contaminação por mercúrio dos rios, animais silvestres e do homem (RAMOS e RODRIGUES, 2018).

Pesquisas recentes evidenciaram que comunidades indígenas próximas aos garimpos vêm sofrendo com grandes contaminações por diversos metais pesados e tóxicos oriundos da prática garimpeira (FIOCRUZ, 2016; VEGA *et al.*, 2018).

De acordo com Barreto e Sirotheau (2001), foi em 1850 que ocorreu o regime de propriedade territorial no Brasil, onde teve o início de terras públicas e privadas, e as áreas indígenas se enquadravam em áreas privadas. Tal divisão foi negativa para os povos indígenas como consequência de uma falta de organização consolidada que cuidasse de seus interesses. De acordo com o IBGE (2010), 1% da população brasileira enquadrava-se como indígena, distribuindo-se em 305 etnias distintas.

De acordo com Ribeiro (2016), desde o período colonial os indígenas têm sofrido violações em todas as esferas, principalmente com relação ao território. Nota-se no decorrer do tempo que grande parte das políticas governamentais não priorizavam o direito à posse de tais territórios pelos povos indígenas, sendo isso em nome de interesses econômicos.

Durante os anos de regime militar, foi delineada uma rota de desenvolvimento econômico para a Amazônia, onde a exploração pelo forte capital estrangeiro foi justificada pelo progresso, ou seja, os danos causados à população da região e ao ambiente foram aceitos em favor do crescimento e do aumento econômico (FURTADO, 2020).

Para entender a dinâmica e as alterações que ocorreram nesses ambientes, visualizando suas transformações, uma possibilidade efetiva é a utilização de técnicas de geoprocessamento. Em especial as ferramentas do sensoriamento remoto, que tem um papel essencial no monitoramento do uso e cobertura da terra, mostrando principalmente os impactos causados por fenômenos naturais e antrópicos, como os desmatamentos, queimadas, expansão urbana, ou outras alterações do uso e da ocupação da terra, pois permite a análise de dados históricos e também de locais inacessíveis, como algumas regiões do bioma Amazônico. Após a obtenção destes dados, é gerada a informação do monitoramento através da classificação de imagens que utiliza um composto de técnicas matemáticas ou estatísticas para automatizar a identificação de todos os pixels de uma imagem em classes de uso e cobertura da terra (FLORENZANO, 2002; LIANG *et al*, 2012).

A classificação de áreas degradadas pela atividade garimpeira é um tanto complexa por se tratar de áreas parecidas com as de desmatamento, tendo como o principal diferencial a coloração do solo, por ser uma atividade que utiliza equipamentos de escavação. Sendo assim, a integração de técnicas para geração de algoritmos baseados em conhecimento pode vir a ser de grande valia para o mapeamento destas áreas.

Seria interessante mencionar algum aspecto referente à localização da terra indígena no resumo e na introdução para contextualizar geograficamente o trabalho.

2. OBJETIVOS

O objetivo deste trabalho foi mapear áreas degradadas oriundas de atividade garimpeira na região das terras indígenas Munduruku utilizando multisensores e classificação baseada em conhecimento.

Os objetivos específicos são:

- Desenvolver um modelo baseado em conhecimento eficaz para a classificação de áreas de garimpo;
- Mapear a expansão de áreas degradadas pela atividade de garimpo durante os anos de 2010 a 2021.

3. REVISÃO DA LITERATURA

A revisão de literatura do presente trabalho apresentará a atividade garimpeira no Brasil, a atividade garimpeira na Amazônia, a atividade garimpeira em Terras Indígenas e a atividade garimpeira na Terra Indígena Munduruku. Serão abordadas as Geotecnologias no meio ambiente, a integração multisensores, classificação baseada em conhecimento e a validação do desempenho classificatório.

3.1 ATIVIDADE GARIMPEIRA NO BRASIL

A atividade garimpeira é presente no Brasil desde a época da colonização, o que está ligado profundamente à nossa história. De acordo com Veiga, Silva e Hinton (2002), durante a crise na Europa no século XVII, a Coroa Portuguesa decidiu incentivar a garimpagem e, assim, propôs uma recompensa aos que mais se destacavam nas descobertas do ouro. No mesmo século, houve a regulamentação dos métodos utilizados durante a extração, e foi também determinado que, para tal atividade, era necessário o pagamento de tributos por cada escravo empregado na extração.

Charles Boxer (1969), em estudos sobre o garimpo no Brasil, traz que diferentes grupos paulistas encontraram ouro quase que simultaneamente em diversas regiões que hoje correspondem ao estado de Minas Gerais. Como consequência das descobertas e da abertura de minas, no final do século XVII a região que antes era praticamente deserta, tornou-se povoada. O desenvolvimento da mineração determinou os ritmos e os modelos de povoamento, fixando os trabalhadores e incentivando o comércio e a agricultura.

Segundo Costa (2002), o termo “garimpeiro” surgiu na região das minas em inícios do século XVIII e tinha como significado aqueles que, desrespeitando a legislação da coroa portuguesa, mineravam as jazidas localizadas em pontos ermos do território, escondidas nas “garimpas” das serras. A etimologia da palavra garimpeiro já denotava ilegalidade, marginalidade e repressão da força de trabalho.

De acordo com Costa (2007), no Brasil do século XVIII, o sistema minerário era dividido em dois: mineração legal e mineração ilegal. A mineração legalizada tinha alta capacidade extrativa e econômica, conforme a ordem legal da compra das datas, pagamento dos impostos e taxas de escravos. De outro lado, a mineração ilegal era realizada por mestiços,

aventureiros, negros alforriados, ou mesmo mineradores que não tiveram como arcar com os extorsivos preços das datas minerárias. Em 1817 iniciou-se a procura do ouro, onde os grupos com maior poder econômico eram privilegiados e os pequenos proprietários eram excluídos. Durante o século XIX, com o advento da cultura do café, houve a diminuição da atividade garimpeira. Em 1930, com Getúlio Vargas, foi estabelecido um direcionamento distinto à questão mineral e, por consequência, ao garimpeiro. Após a década de 60, houve o surgimento do método de garimpagem com utilização de bases tecnológicas, deixando assim a caracterização de um trabalho rudimentar e de pequena escala no passado.

De 1934 a 1967, o proprietário da terra tinha a preferência para a pesquisa e a extração do minério encontrado em sua terra, além do direito de participação nos lucros da lavra. Com a Constituição de 1988 os minérios foram considerados bens da União. E hoje em dia são estabelecidos acordos entre os proprietários de terras e os garimpeiros, uma vez que estes não possuem a concessão de lavra. Já a partir dos anos 80 houve uma enorme expansão do garimpo, e tal crescimento gerou um choque direto entre o garimpo e o aparato do Estado. A partir de 1985 inicia-se a fase de exaustão e decadência das jazidas e começam a aparecer os conflitos pela administração do garimpo (COSTA, 2007).

Estudo publicado pelo Projeto MapBiomás (2021) traz que de 1985 a 2020 a área de mineração cresceu no Brasil cerca de seis vezes, sendo considerado nesse cálculo as áreas de garimpo legal e ilegal, e a atividade industrial.

3.2 ATIVIDADE GARIMPEIRA NA AMAZÔNIA

Segundo Cordani e Juliani (2019), a Amazônia é responsável por um terço da produção mineral brasileira. O patrimônio já conhecido de suas jazidas minerais assegura ao Brasil um excelente potencial, semelhante ao de países de dimensões similares, como o Canadá ou a Austrália. Entretanto, a vulnerabilidade ambiental da região com seus rios e a floresta tropical a colocam sujeita a muitos possíveis impactos na retirada de recursos minerais, devidos principalmente à garimpagem.

Salomão e Veiga (2016) trazem que, na Amazônia, existem simultaneamente três estágios tecnológicos na utilização de recursos minerais: coleta mineral (povos indígenas), extrativismo mineral (garimpos) e mineração organizada (empresas). O primeiro estágio ou a coleta mineral, está relacionada ao uso de objetos e substâncias minerais disponibilizados pela natureza, a exemplo dos instrumentos de pedra, adornos e pigmentos minerais utilizados por povos indígenas e, portanto, não traz danos ambientais. Já o extrativismo mineral e a mineração

organizada possuem características muito diferenciadas quanto aos impactos que provocam, especificamente no caso de desmatamento e de degradação ambiental. O extrativismo mineral, conhecido informalmente como “garimpo”, opera com medidas simples, nas quais predominam trabalhos manuais para remoção e separação de bens minerais em depósitos secundários superficiais (aluviões, colúvios). Por outro lado, a mineração organizada, embora as minas sejam localizadas pontualmente, atua em grande escala em operações ordenadas e tecnicamente conduzidas de lavra e beneficiamento de minérios diversos, precedidas de planejamento e de pesquisa mineral.

Há diversos problemas oriundos da prática de garimpo, como a alteração morfológica dos rios em função da escavação de trincheiras e labirintos e a poluição por mercúrio. Há uma estimativa de que para cada 1 kg de ouro produzido, 1,3 kg de mercúrio é emitido para o ambiente. Pereira (1991) discorre sobre a aparente sensação de subsídio gerado pelo próprio governo em função da garimpagem, aparentemente pela grande geração de riquezas, através da criação de estradas para áreas de garimpo, estabelecimento de reservas garimpeiras e aumento das taxas de importação de ouro para encorajar a produção doméstica.

Estudos abordam as consequências da garimpagem na Amazônia, trazendo, sobretudo, tópicos de impactos ambientais (Silva, 1988); impactos sociais e da saúde (Amoras, 1991); prostituição, trabalho da mulher (Dimenstein, 1992; Rodrigues, 1994); efeitos nas culturas indígenas (Burkhalter, 1982); significado econômico da mineração (MacMillan, 1993; Pereira, 1991; da Silva, 1994); políticas públicas minerais (Dourado, 1993); e técnicas alternativas para a garimpagem do ouro.

3.3 ATIVIDADE GARIMPEIRA EM TERRAS INDÍGENAS

O censo de 2010 (IBGE, 2010) trouxe que a população indígena brasileira somava 896,9 mil habitantes, o que corresponde a menos de 1% da população brasileira. Os povos indígenas distribuem-se entre 305 etnias distintas, caracterizadas por diferentes línguas, costumes e culturas. Melatti (2007) define que Índio é todo o indivíduo reconhecido como membro por uma comunidade pré-colombiana que se identifica como etnicamente diversa da nacional, e é considerada indígena pela população brasileira com que está em contato.

De acordo com a legislação brasileira, a exploração das riquezas minerais só pode ser efetivada com autorização do Congresso Nacional, desde que ouvidas as comunidades afetadas e desde que esteja assegurada a estas uma participação nos resultados da lavra, na forma da lei. A legislação traz também que a mineração, assim como qualquer outra atividade econômica,

deve estar fundamentada dentro dos princípios da sustentabilidade, de forma a assegurar uma melhoria na qualidade de vida da população e um meio ambiente saudável, além da rentabilidade econômica. Nesse sentido, para que possa existir uma atividade minerária em terras indígenas, faz-se necessário que esta, além de gerar crescimento econômico, seja compatível com a preservação dos recursos naturais e com a garantia dos direitos culturais dos povos indígenas (CURI, 2005).

A atividade garimpeira ocasiona impacto social significativo. Há registros de que a invasão de garimpeiros em territórios indígenas no estado de Roraima, gerou diversas consequências como, doenças e conflitos culturais. A prática ilegal da mineração ocasionou prejuízos ao meio ambiente, retirando o direito a um ambiente preservado para as presentes e futuras gerações e das sociedades indígenas, sendo conhecidos os severos danos ambientais e sociais decorrentes principalmente do uso de mercúrio (VEGA *et al.*, 2018; FIOCRUZ, 2016).

Ramos e Rodrigues (2018) demonstraram que a mineração artesanal em terras indígenas culmina na construção de vilas por garimpeiros, no meio da floresta, algumas com até mil habitantes, o que se constitui em crime que afeta, significativamente, o meio ambiente e o patrimônio da União (RIBEIRO, IASBIK, 2019).

No Brasil do século XXI, tem-se espaços onde a ausência do Estado ocasiona conflitos entre indígenas, que lutam pelo legítimo direito de ter prestações de políticas públicas, e garimpeiros, que trabalham de forma ilegal, extraíndo ouro dos leitos dos rios amazônicos ou às suas margens, construindo suas identidades e vivendo sob suas regras. Os não indígenas se aproveitam da ausência do Estado para viverem e extraírem recursos naturais da floresta de forma ilegal (WOLKMER, 2015).

3.4 ATIVIDADE GARIMPEIRA EM TERRAS INDÍGENAS MUNDURUKU

A Terra Indígena Munduruku possui uma população de 6.518 indígenas em uma área de 2.382.000 hectares. Está localizada na região sudoeste do Estado do Pará, no Município de Jacareacanga, margem direita do Rio Tapajós. A Terra Indígena Munduruku faz limite a noroeste com a Terra Indígena Sai Cinza e a sul-sudeste com a Terra Indígena Kayabi. O povo Munduruku se concentra em sua maior parte na Terra Indígena Munduruku, onde os habitantes desta Terra Indígena distribuem-se em aproximadamente 80 aldeias. As principais etnias são Apiaká, Kayabi, Kayapó, Tembé e Canoeiro. As aldeias podem ser formadas por apenas uma família com quatro membros ou por dezenas de famílias (FUNAI, 2008).

Segundo o Instituto Socioambiental (2021), houve um aumento de mais de 360% em áreas de garimpo na região da Terra Indígena Munduruku entre 2019 e 2021, representando cerca de mais de dois mil hectares. Entretanto, a atividade garimpeira nessa região não é recente, e teve início na década de 50, com a descoberta de ouro no rio das Tropas, afluente do rio Tapajós, limite nordeste da terra indígena, sendo intensificada na década de 80, no auge da corrida do ouro (NEPOMUCENO, 2019).

Monteiro *et al.* (2014), fala sobre como o reconhecimento do potencial aurífero da região fez com que, em 1983, o Ministério de Minas e Energia decretasse a criação da “Reserva Garimpeira do Tapajós”, localizada na região leste da terra indígena, inserida nos limites da Província Mineral do Tapajós. Esse período também marca a facilitação na região para a exploração, com a criação de acessos e pistas de pousos. Importante frisar que tal decreto foi realizado sem a participação do povo Munduruku pois, até a promulgação da Constituição Federal de 1988, os povos indígenas estavam sob a tutela legal do Estado, de forma que o Estado podia tomar decisões sem consultá-los. Já em 1995, o Estado brasileiro criou o Projeto Mineral do Tapajós- PROMIN-TAPAJÓS, selecionando regiões em função do contexto geológico e do potencial das mineralizações auríferas (ARAÚJO, 2000).

Entre as terras que mais sofrem com as pressões da exploração mineral ilegal e pelas especulações de grandes empresas mineradoras, estão as Terras Indígenas Munduruku, Sai Cinza (povo Munduruku), homologadas por decretos presidenciais em 2004 e 1991, respectivamente, e a Terra Indígena Sawre Muybu (povo Munduruku), que teve Relatório Circunstanciado de Identificação e Delimitação (RCID) publicado em abril de 2016. Essas áreas contam com milhares de processos protocolados junto à Agência Nacional de Mineração (ANM), e estima-se que nessa região a economia do ouro movimentava anualmente milhões de reais, onde as tensões sociais vêm aumentando, em especial com os anúncios do governo federal em 2019 de que regulamentará mineração em terras indígenas e com suas investidas voltadas à simplificação do regime de outorga de lavra garimpeira (NEPOMUCENO, 2019).

3.5 GEOTECNOLOGIAS NO MEIO AMBIENTE

Com o decorrer dos anos, as geotecnologias se tornaram essenciais nos estudos ambientais. Por meio destas ferramentas, é possível a extração de informações, tanto históricas quanto em tempo real, sobre áreas de difícil acesso (SOUZA; DA CUNHA, 2020). Faz-se necessário o uso de diferentes escalas temporais e espaciais na busca por uma avaliação confiável dos ambientes naturais e urbanos. A utilização das imagens obtidas por sensores a

bordo de satélites é uma forma confiável, efetiva e econômica na obtenção de dados que irão auxiliar no monitoramento e modelagem dos diferentes fenômenos. A aplicação do geoprocessamento em estudos ambientais e antrópicos viabiliza um maior entendimento dos processos e suas dinâmicas, trazendo um aumento da produtividade dos estudos, além de possibilitar o manejo dos dados e suas informações (CARVALHO, NETO, 2011; LIMA, 1999).

Fitz (2008) menciona a importância do conhecimento técnico dos profissionais com respeito ao uso das ferramentas e dados que o Sensoriamento Remoto dispõe. Todo o avanço das geotecnologias vem da necessidade de se ter uma melhor compreensão do espaço geográfico e da relação do homem e do ambiente. O avanço tecnológico trouxe um destaque para os Sistemas de Informações Geográficas (SIGs) e para a área de Sensoriamento Remoto.

3.6 SATÉLITES E SENSORES

A definição de um satélite é um corpo de menor massa que orbita um corpo de maior massa, podendo ser naturais ou artificiais. Os satélites artificiais possuem grandes aplicações, dentre eles os satélites científicos que fotografam objetos espaciais ou transportam experimentos, os de comunicação que transmitem sinais das ondas de rádio e televisão, os meteorológicos que realizam previsões climáticas, os de posicionamento que auxiliam no posicionamento geográfico, e os de observação da Terra, ou seja, os satélites de sensoriamento remoto que imageiam a superfície terrestre. As informações são coletadas através de sensores e sua trajetória corresponde a sua órbita, onde se destacam pela sua utilidade (BRASIL, 2005).

Dentre os diversos satélites de observação da Terra, o CBERS 4A e o LANDSAT são satélites com dados de distribuição gratuita, que facilitam o acesso de pesquisadores ao monitoramento de áreas de difíceis acessos.

3.6.1 CBERS 04A

O CBERS 04A é um satélite cujos sensores operam no espectro da luz visível e no comprimento de onda infravermelho com resolução espacial variando de 2 a 60 metros. Foi lançado no ano de 2019, em parceria entre o Brasil e a China (INPE, 2019).

O satélite é equipado com 3 (três) câmeras imageadoras: Câmera Multiespectral e Pancromática de Ampla Varredura (WPM), Câmera Multiespectral (MUX) e Câmera Imageadora de Campo Largo (WFI). As características principais destas câmeras estão apresentadas no Quadro 1 (INPE, 2019).

Quadro 1 - Caracterização das câmeras imageadoras do satélite CBERS 04A.

Características das câmeras CBERS 04A			
Características	WPM	MUX	WFI
Bandas Espectrais ¹	0,45-0,52µm (B) 0,52-0,59µm (G) 0,63-0,69µm (R) 0,77-0,89µm (NIR) 0,45-0,90 µm (PAN)	0,45-0,52µm (B) 0,52-0,59µm (G) 0,63-0,69µm (R) 0,77-0,89µm (NIR)	0,45-0,52µm (B) 0,52-0,59µm (G) 0,63-0,69µm (R) 0,77-0,89µm (NIR)
Resolução Espacial	Multiespectral: 2 m Pancromática: 8 m	16,5 m	55 m
Largura da Faixa Imageada	92 km	95 km	684 km
Revisita	31 dias	31 dias	5 dias
Quantização	10 bits	8 bits	10 bits

Nota: B = Blue, G = Green, R = Red, NIR = Near Infrared, PAN = Panchromatic.

Fonte: INPE (2019).

3.6.2 Landsat 5

A missão Landsat 5, iniciada no ano de 1984 e projetada para uma vida útil de 3 (três) anos, operou fornecendo dados durante 29 (vinte e nove) anos consecutivos, até ser desativada em 2013 (USGS, 2021).

O satélite possuía 2 (dois) sensores a bordo, o *Multispectral Scanner System* (MSS), composto por 5 (cinco) bandas, e o *Thematic Mapper* (TM), contendo 7 (sete) bandas, as quais são especificadas no Quadro 2.

Quadro 2 - Características dos sensores a bordo do satélite Landsat 5.

Características do Landsat 5		
Características	TM	MSS
Bandas Espectrais	0.45 - 0.52 µm (B) 0.52 - 0.60 µm (G) 0.63 - 0.69 µm(R)	0.5 - 0.6 µm(G) 0.6 - 0.7 µm (R) 0.7 - 0.8 µm (NIR)

	0.76 - 0.90 μm (NIR) 1.55 - 1.75 μm (MID) 10.4 - 12.5 μm (TIR) 2.08 - 2.35 μm (NIR)	0.8 - 1.1 μm (NIR) 10.41-12.6 μm (TIR)
Resolução Espacial	B, G, R, NIR, MID: 30 m TIR: 120 m NIR: 30 m	16,5 m
Largura da Faixa Imageada	185 km	185 km
Revisita	16 dias	16 dias
Quantização	8 bits	8 bits

Nota: B = Blue, G = Green, R = Red, NIR = Near Infrared, MID = Mid Infrared, TIR = Thermal infrared
Fonte: USGS (2021).

3.6.3 Landsat 8

A missão Landsat 8, também conhecida como *Landsat Data Continuity Mission* (LDCM), entrou em operação no ano de 2013 e encontra-se ativo atualmente. Opera com os sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS), que são descritos no Quadro 3 (USGS, 2021).

Quadro 3 - Características dos sensores a bordo do satélite Landsat 8.

Características do Landsat 8		
Características	OLI	TIRS
Bandas Espectrais	0.433 - 0.453 μm (C) 0.450 - 0.515 μm (B) 0.525 - 0.60 μm (G) 0.630 - 0.680 μm (R) 0.845 - 0.885 μm (NIR) 1.560 - 1.660 μm (MID) 2.100 - 2.300 μm (MID) 0.500 - 0.680 μm (PAN) 1.360 - 1.380 μm (Cirrus)	B10 - LWIR -1 (10.60 - 11.19 μm) B11 - LWIR - 2 (11.50 - 12.51 μm)

Resolução (?)	B1 - B7: 30 m B8: 15 m B9: 30 m	100 m
Largura da Faixa Imageada	185 km	185 km
Revisita	16 dias	16 dias
Quantização	12 bits	12 bits

Nota: C= Coastal, B = Blue, G = Green, R = Red, NIR = Near Infrared, MID = Mid Infrared, PAN = Pancromática.

Fonte: USGS (2021).


3.7 TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

O refinamento de informação visual para a interpretação humana e o processamento de dados de cenas para interpretação automática através de máquinas são áreas principais de aplicação das técnicas de Processamento Digital de Imagens (PDI). Utilizando as técnicas de PDI é possível analisar dados em várias faixas do espectro eletromagnético, e com isso torna-se possível a utilização de dados oriundos de diversas fontes. Esses dados são processados em três etapas para chegar ao produto, sendo elas: o pré-processamento, o realce e a classificação (GONZALEZ e WOODS, 2000).

Dentre as diversas formas de classificação de imagens, destaca-se a classificação baseada em conhecimento, conhecida também como AIDA (*Automatic Image Data Analyser*). Trata-se de um sistema (Figura 1) que organiza como rede semântica o processo de análise, utilizando imagens multisensor e dados auxiliares (primários e secundários), tendo como resultado a classificação de uma área (BÜCKNER, 2000).

A vantagem dessa técnica é a possibilidade de obter a classificação de uso e cobertura do solo.

Figura 1 - Componentes do sistema geoAIDA.



Fonte: Bückner (2000).


3.7.1 Classificação supervisionada

Os algoritmos de classificação têm por objetivo a extração de informações de feições em imagens, ou seja, é a interpretação da energia eletromagnética refletida em classes de cobertura da terra (LILLESAND e KIEFER, 1994). Segundo Crósta (1992), a classificação de imagens é dividida em classificação supervisionada e não-supervisionada. Para a classificação supervisionada é necessário um conjunto de amostras de treinamento que representam cada classe da área de estudo, sendo baseada em regras estatísticas pré-estabelecidas. Alguns exemplos de algoritmos para classificação supervisionada são o *Random Forest* e o *Support Vector Machine*.

3.7.1.1 Random Forest

O classificador *Random Forest* é formado por uma coleção de árvores de decisão, como apresentado na Figura 2, estruturado a partir de uma reamostragem aleatória do agrupamento de treinamento original, onde a classificação se dá pela seleção da classe vencedora em termos de número de votos acumulados. São definidos dois parâmetros de entrada para executar as árvores de decisão: o número de árvores a serem geradas (*Ntree*) e o número de variáveis a serem testadas (*Mtry*). Quando se tem um grande número de *Ntree*, o algoritmo produz árvores com maiores variações e baixas tendências (BREIMAN, 2001).

Figura 2 - Representação do algoritmo Randon Forest.




Fonte: Adaptada de Chakure (2019).

3.7.1.2 Support Vector Machine

O algoritmo *Support Vector Machine* (SVM) é uma técnica de classificação binária que utiliza hiperplanos para a separação dos alvos entre classes. Neste algoritmo são utilizados hiperplanos lineares e não lineares. No hiperplano linear, o algoritmo utiliza uma linha para a separação dos dados em classes. No entanto, pode ocorrer de ter um conjunto de dados não lineares e, neste caso, são utilizadas técnicas de Kernel, que é o processo de reorganização dos objetos (VAPNIK, 1995; ALVES e FRAGAL, 2011).

A técnica de Kernel possui várias funções, como a linear, polinomial, *Radial Basis Function* (RBF) e sigmoide. Essas funções trabalham a projeção de um dado de espaço dimensional baixo para um espaço de alta dimensão, fazendo assim com que os dados possam ser separados de acordo com a classificação definida pelo usuário, conforme mostrado na Figura 3. (OOMMEN *et al.*, 2008; EXELIS, 2015).


Figura 3 - Exemplo da aplicação da técnica de Kernel.



Fonte: Sharma (2019).

Conforme mostrado na Figura 4, os dados possuem dois possíveis hiperplanos lineares (A e B) que representam as classes das amostras, e, diante disso, torna-se necessário avaliar qual hiperplano representa a separação do conjunto de dados em classes. O parâmetro de escolha do hiperplano é dado pela maior margem entre as classes, ou seja, a linha que fica o mais distante possível das amostras mais próximas (VAPNIK, 1995).

Figura 4 - Exemplo da aplicação do hiperplano linear.




Fonte: Harp (2018).

3.7.1.3 Geographic Object-Based Image Analysis (GEOBIA)

De acordo com Castilla e Hay (2008), a análise baseada em objetos geográficos possui métodos de automatização que visam a segmentação de imagens de sensoriamento remoto em objetos de imagem onde, através de suas características, possibilita a geração de informações importantes para análises de Sistema de Informação Geográfica (Figura 5). As informações geradas pelo GEOBIA são eficazes para o usuário perceber, interpretar e responder algumas questões sobre a dinâmica que ocorre no meio ambiente.

Figura 5 - Processo da análise baseada em objetos geográficos.



Fonte: Macedo (2010).

A segmentação é uma etapa importante no processo de análise de imagens. Neste procedimento, subdivide-se a imagem em regiões semelhantes, é finalizado até que todos os

alvos de interesse tiverem sido isolados. Esse processo extrai informações das imagens digitais utilizando os valores de níveis digitais em conjunto das propriedades espaciais, espectrais e textura, isolando as regiões que possuem semelhanças e que estão espacialmente próximas. (GONZALEZ e WOODS, 2000; SOLUTIONS ,2008). No Quadro 4 é possível analisar alguns atributos espaciais com as respectivas descrições

Quadro 4 - Descrição dos atributos espaciais.

Atributos Espaciais	
Atributo	Descrição
Área	Área total do polígono, menos a área dos furos.
Comprimento	O comprimento combinado de todos os limites do polígono, incluindo os limites dos furos.
Compacidade	Uma medida de forma que indica a compacidade do polígono. Um círculo é a forma mais compacta com um valor de $1/\pi$.
Convexidade	Os polígonos são convexos ou côncavos. Este atributo mede a convexidade do polígono. O valor de convexidade para um polígono convexo sem furos é 1,0, enquanto o valor para um polígono côncavo é menor que 1,0
Solidez	Uma medida de forma que compara a área do polígono com a área de um casco convexo ao redor do polígono. O valor de solidez para um polígono convexo sem furos é 1,0 e o valor para um polígono côncavo é menor que 1,0.
Redondeza	Uma medida de forma que compara a área do polígono com o quadrado do diâmetro máximo do polígono. O "diâmetro máximo" é o comprimento do eixo principal de uma caixa delimitadora orientada que envolve o polígono. O valor de arredondamento para um círculo é 1 e o valor para um quadrado é $4/\pi$.
Fator de Forma	Uma medida de forma que compara a área do polígono com o quadrado do perímetro total. O valor do fator de

	forma de um círculo é 1 e o valor de um quadrado é $\pi/4$.
Alongamento	Uma medida de forma que indica a razão entre o eixo maior do polígono e o eixo menor do polígono. Os eixos maior e menor são derivados de uma caixa delimitadora orientada contendo o polígono. O valor de alongamento para um quadrado é 1,0 e o valor para um retângulo é maior que 1,0
Retangularidade	Uma medida de forma que indica quão bem a forma é descrita por um retângulo. Este atributo compara a área do polígono com a área da caixa delimitadora orientada que envolve o polígono. O valor de ajuste retangular para um retângulo é 1,0 e o valor para uma forma não retangular é menor que 1,0.
Direção principal	O ângulo subtendido pelo eixo maior do polígono e o eixo x em graus. O valor da direção principal varia de 0 a 180 graus. 90 graus é Norte/Sul e 0 a 180 graus é Leste/Oeste.
Eixo Maior	O comprimento do eixo principal de uma caixa delimitadora orientada que envolve o polígono. Os valores são unidades de mapa do tamanho do pixel. Se a imagem não for georreferenciada, as unidades de pixel serão relatadas.
Eixo Menor	O comprimento do eixo menor de uma caixa delimitadora orientada que envolve o polígono. Os valores são unidades de mapa do tamanho do pixel. Se a imagem não for georreferenciada, as unidades de pixel serão relatadas.
Número de furos	O número de furos no polígono. Valor inteiro.
Relação área/furos	A razão entre a área total do polígono e a área do contorno externo do polígono. O valor da razão sólida do furo para um polígono sem furos é 1,0

Fonte: Solutions (2008).

Os atributos relacionados as propriedades espectrais dos pixels de cada região, sendo elas calculadas para cada banda espectral são: Valor mínimo do pixel, Valor máximo do pixel, Média dos valores digitais, Desvio padrão dos valores digitais, Razão entre bandas, Matiz, Saturação e Intensidade.

Para os atributos de textura, é analisada a frequência do Nível Digital (ND) da imagem, com isso é estimada a textura de cada região da imagem, sendo elas o Intervalo de textura, Média de textura, Variância da textura e Entropia da Textura.

Ao definir os parâmetros para segmentação é preciso certificar que os objetos não sejam agrupados em frações de outros objetos. Outro ponto importante é garantir que a segmentação não seja dividida em regiões pequenas, conhecidas como supersegmentação, ou em grandes regiões, conhecidas como subsegmentação (SOLUTIONS ,2008).

3.7.1.4 Validação do processo de classificação

A validação da classificação é um processo necessário para avaliar a precisão do processo de classificação. A validação é realizada através do cruzamento das amostras consideradas como verdadeiras e a classe que foi determinada pelo algoritmo no mesmo local. A validação é realizada através da análise da matriz de confusão, índice Kappa e Exatidão Global (RICHARDS; JIA, 2006).

A matriz de confusão, ou também conhecida como matriz de erros, é uma matriz quadrada caracterizada por linhas e colunas onde as unidades amostrais são atribuídas a uma categoria específica de uma classificação. As linhas indicam a classificação gerada pelo algoritmo selecionado, enquanto que as colunas representam a verdade de campo (Figura 6) (CONGALTON;GREEN, 1999). Congalton e Green (1999), afirmam que a matriz de confusão é o método eficaz para representar a qualidade de um mapa. A diagonal principal da matriz indica a quantidade de amostras que foram classificadas corretamente, já os componentes fora da diagonal, implicam na quantidade de amostras que foram incluídos de forma equivocada em uma classe.

A matriz possibilita o aperfeiçoamento da classificação de imagens, pois tem como base descrever a precisão e apresentar os erros, sendo calculada através da comparação entre a verdade de campo e os resultados da classificação (FOODY, 2002; MATSUKUMA, 2002; DINIZ, 2019).

Figura 6 - Matriz de confusão.

		Referência			
		1	2	k	Total da linha
Classificação	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Total da coluna		n_{+1}	n_{+2}	n_{+k}	n

Fonte: Adaptado de Congalton e Green (1999).

O índice Kappa é uma função, Equação 01, proposta em 1960 por Jacob Cohen. É um método estatístico utilizado para a avaliação da precisão temática e é calculado com base nos elementos da matriz de confusão (BRITES, SOARES e RIBEIRO, 1996). É definido como a conformidade entre a classificação e a verdade de campo para escalas nominais (COHEN,1960).

$$K = \frac{\sum_{k=1}^q n_{kk} - \sum_{k=1}^q n_{k+} n_{+k}}{n^2 - \sum_{k=1}^q n_{k+} n_{+k}} \quad (1)$$

onde:

q = número de classes;

n_{k+} = total de elementos classificados para uma categoria k;

n_{+k} = total de elementos de referência amostrados para uma categoria k;

n_{kk} = elementos da diagonal principal;

n = número total de amostras.

Para uma melhor representação qualitativa da classificação, Landis e Koch (1977), fizeram a relação dos intervalos dos índices com classes nominais, conforme o Quadro 5.

Quadro 5 – Classes do coeficiente Kappa.

Kappa	Classe
< 0	Péssima
$0 < K < 0,2$	Ruim

0,2 < K < 0,4	Razoável
0,4 < K < 0,6	Bom
0,6 < K < 0,8	Muito bom
0,8 < K < 1,0	Excelente

Fonte: Adaptado Landis e Koch (1977).

A Exatidão Global (Po), Equação 2, é calculada dividindo a soma dos valores da diagonal principal da matriz de confusão pelo número total de amostras coletadas n (HELLDÉN,1980).

$$Po = \frac{\sum_{k=1}^q n_{kk}}{n} \quad (2)$$

onde:

q = número de classes;

n_{kk} = elementos da diagonal principal;

n = número total de amostras.

3.7.2 Índices espectrais

Os índices espectrais são gerados a partir da relação entre as bandas dos sensores, pois cada alvo possui uma resposta em diferentes regiões espectrais. São informações importantes para o monitoramento da dinâmica natural com ou sem interferência antrópica. Os índices possibilitam diferenciar os tipos de cobertura e uso do solo (FEITOSA, 2004; MOREIRA, 2005).

Dentre os diversos índices espectrais, o mais utilizado para a identificação de vegetação é o Índice de Vegetação de Diferença Normalizada (*NDVI - Normalized Difference Vegetation Index*). Já para a identificação de água é o Índice de Água Diferença Normalizada (*NDWI - Normalized Difference Water Index*).

O NDVI é o índice utilizado para estudos de caracterização e monitoramento da vegetação, indicando a estimação de biomassa e observando mudanças causadas por atividades antrópicas (JENSEN, 2009). De acordo com Moreira (2000), o índice é calculado pela razão

normalizada entre as bandas do vermelho e do infravermelho próximo. Trata-se de um parâmetro adimensional e possui variação entre -1 e 1, onde o valor 1 indica alvos com presença de vegetação e o -1 indica alvos diferentes de vegetação.

O *NDWI* tem como objetivo indicar a umidade presente nos dosséis de vegetação, assim como alterações na biomassa, e estresse presente na planta. O índice também é utilizado para dados hidrológicos, principalmente a identificação de cursos d'água, áreas inundadas, etc. O índice é calculado utilizando as bandas do verde e do infravermelho próximo. Obtêm-se como resultado valores variando entre -1 e 1, onde o valor 1 representa a presença de umidade e valores próximos de -1 representa a presença de outros alvos (BRENNER e GUASSELLI; MEMON *et al.*, 2015).


4. METODOLOGIA

Neste capítulo será apresentada a localização e caracterização da área de estudo, bem como os materiais e procedimentos metodológicos utilizados para a execução deste trabalho.

4.1 LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área selecionada foi a Terra Indígena (T.I.) Munduruku, que possui uma área de 2.382.000 hectares. A área deveria representar um local onde a presença de atividade garimpeira é existente. A T.I. está situada no estado do Pará, fazendo divisa com os estados do Amazonas e Mato Grosso, conforme mostra a Figura 7, sendo também confrontante do Parque Nacional do Juruena, a Floresta Nacional do Crepori e a Área de Proteção Ambiental Tapajós.

Figura 7 - Localização da área de estudo - Terra Indígena Munduruku.



Fonte - A autora (2022).

Para facilitar a análise do modelo mais eficaz para o mapeamento das atividades garimpeiras, foi selecionada uma área piloto (Figura 7), com as mesmas características da área de estudo. Parte da área está na Floresta Nacional do Crepori, no estado do Pará, e também na Área de Proteção Ambiental do Tapajós. Para a delimitação da região, foi feito um *buffer* através de um ponto de localização com Latitude 7°10'3.74"S e Longitude 57°16'12.91"O, (SIRGAS2000) com uma distância de 20.000 m, contendo uma área de 160.125,0000 hectares. Assim, primeiramente foi realizada a análise do melhor modelo de classificação de atividade garimpeira para a área piloto, e posteriormente, o mesmo modelo foi aplicado para a área de estudo.

4.2 MATERIAIS E SOFTWARES


Para a realização desse estudo foi necessária a aquisição dos seguintes materiais:

- Imagens do satélite Landsat 5/TM referentes ao ano de 2010;
- Imagens do satélite Landsat 8/OLI referentes aos anos de 2016 e 2018;
- Imagens do satélite CBERS 04A, referentes ao ano de 2021;
- Arquivo *shapefile* das áreas desmatadas - Projeto PRODES;
- Arquivo raster do MapBiomas da cobertura do solo para os anos de 2010, 2016, 2018 e 2021, disponível em: <<https://mapbiomas.org>>.

4.3 PROCEDIMENTOS METODOLÓGICOS

Os procedimentos metodológicos utilizados no estudo estão apresentados na Figura 8.

Figura 8 - Fluxograma metodológico.



Fonte: A autora (2021).

4.3.1 Coleta de Dados


Inicialmente foi realizada a aquisição de imagens Landsat 5/Sensor TM (2010) e Landsat 8/Sensor OLI (2016 e 2018) na plataforma USGS, CBERS 04A/Sensor WPM (2021) disponíveis na plataforma Catálogo de Imagens – INPE.

Em seguida, foram adquiridos os dados secundários como as áreas desmatadas, áreas de garimpo e o mapa de cobertura e uso do solo do MapBiomass. Estes dados foram utilizados para a base de dados auxiliares dos modelos de classificação baseada em conhecimento.

4.3.2 Pré-processamento dos dados ópticos

A etapa do pré-processamento está detalhada na Figura 9.

Figura 9 - Fluxograma metodológico da etapa do pré-processamento.



Fonte: A autora (2021).

A primeira etapa consistiu no empilhamento de bandas, conforme descrita na Tabela 1.

Tabela 1 - Bandas utilizadas para o empilhamento.

Satélite/Sensor	Bandas
Landsat 5/TM	Azul
	Verde
	Vermelho
	Infravermelho Próximo
	Infravermelho Médio
Landsat 8/OLI	Azul
	Verde
	Vermelho
	Infravermelho Próximo
	Infravermelho Médio
CBERS 4A/WPM	Azul
	Verde
	Vermelho
	Infravermelho Próximo

Fonte: A autora (2022).

A segunda etapa executada foi a correção atmosférica das imagens dos satélites Landsat 5 e Landsat 8, utilizando o software *Erdas Imagine*, e o módulo ATCOR. Nesta função é utilizado o algoritmo MODTRAN 4 (*Moderate resolution atmospheric Transmission*), que aumenta a capacidade de predição dos efeitos atmosféricos em ambiente nublado e/ou aerossóis pesados. O processo de correção é utilizado para minimizar os efeitos da atmosfera que influenciam no sinal dos satélites, então a correção atmosférica é imprescindível para retomar as propriedades físicas da superfície (HEXAGON, 2015; LATORRE *et al.*, 2002). As imagens do satélite CBERS4A não passaram por esse procedimento, uma vez que são imagens com nível de processamento L4, ou seja, possuem correção radiométrica e correção geométrica, sem a necessidade de procedimentos adicionais.

Após foi executada o processo de contraste nas imagens que consiste em melhorar a qualidade sob o olho humano, ou seja, aumentar a distinção visual entre alvos presentes na imagem.


Em seguida foi realizado o pré-processamento dos dados que foi dada pelo mosaico que consiste na junção de imagens de diferentes órbita-ponto, obtendo, portanto, apenas uma imagem para a área. Após o mosaico, foi realizado o recorte para a área piloto e posteriormente para a área de estudo.

Foi realizada a reamostragem da imagem CBERS 4A, passando de 8 metros para 30 metros, com a finalidade de fazer a análise temporal dos anos, igualando o tamanho de pixel das imagens LANDSAT.

4.3.5 Geração de dados auxiliares

Para a criação dos modelos de classificação foi necessária a geração de dados auxiliares, que são: os índices espectrais, conforme o Quadro 6, e a classificação supervisionada. As imagens processadas foram os dados de entrada para a geração de cada dado auxiliar. Esta etapa está detalhada na Figura 10.

Figura 10 - Fluxograma metodológico da etapa da geração de dados auxiliares.



Fonte: A autora (2021).

Quadro 6 - Índices espectrais utilizados no estudo.

Índices	Fórmula
NDVI	$\frac{(nir - red)}{(nir + red)}$
NDWI	$\frac{(green - nir)}{(green + nir)}$

Nota: Sendo *nir*=infravermelho próximo, *red*=banda com comprimento de onda na faixa do vermelho, *green* = banda com comprimento de onda na faixa do verde.

Fonte: A autora (2022).

Para a classificação supervisionada foram utilizados os algoritmos classificadores RF (*Random Forest*), SVM (*Support Vector Machine*) e a Classificação Orientada a Objetos (GEOBIA).

4.3.5.1 Amostras de treinamento e validação

As amostras de treinamento foram coletadas por interpretação visual de imagens ópticas respectivas para cada ano de análise, para cada classe foram selecionadas as amostras de treinamento, conforme descrito no Quadro 7. As amostras representam as 4 (quatro) classes de uso e cobertura do solo, conforme descritas no Quadro 8, exceto o ano de 2010 que apresenta 6 (seis) classes.

Quadro 7 - Quantidade de amostras por classe.

Classe	2010	2016	2018	2021
Área antropizada	140	326	209	180
Hidrografia	112	103	100	156
Garimpo	107	213	155	184
Vegetação	229	200	236	205
Nuvem	160	-	-	-
Sombra de nuvem	55	-	-	-

Fonte: A autora (2022).

Quadro 8 - Descrição das classes de uso e cobertura do solo.

Classe	Descrição
Área antropizada	Áreas não vegetadas, incluindo estradas, agricultura e construções
Hidrografia	Áreas que abrangem rios e lagos
Garimpo	Áreas de atividades garimpeiras
Vegetação	Áreas sem ação do homem, com predominância de espécies arbóreas

Fonte: A autora (2022).

4.3.5.2 Classificação de imagens

Nesta etapa, como apresentado na Figura 10, utilizou-se os seguintes parâmetros para gerar a classificação de imagens de acordo com cada algoritmo utilizado: para o RF, foi utilizada as amostras divididas em 30% para a validação e 70% para o treinamento; para o SVM, utilizou-se de 30% das amostras para a validação, 70% para o treinamento e a função *Radial Basis Function* (RBF).

Para a classificação GEOBIA, foi utilizado o software TerraView 5.6.3. Foram realizados vários testes, de forma visual, ou seja, de maneira que houvesse discriminação entre os alvos, dos parâmetros para cada imagem óptica utilizada, com isso, pode-se chegar ao melhor parâmetro para a região.

Para a segmentação, utilizou-se o tipo “Crescimento de Regiões” com parâmetros diferentes para cada ano, de acordo com o Quadro 9, e todas as bandas foram utilizadas para a segmentação. Com o complemento GeoDMA foi realizada a extração de atributos espaciais e espectrais para cada segmentação.

Quadro 9 - Parâmetros utilizados para a segmentação de imagens.

Crescimento de regiões	Landsat 5 (2010)	Landsat 8 (2016)	Landsat 8 (2018)	CBERS 4A (2021)
Tamanho mínimo de segmentos	100	10	10	200
Limiar de similaridade	0,098	0,037	0,055	0,067

Fonte: A autora (2022).

O próximo passo foi a extração de atributos, onde é executada a extração das informações espaciais e espectrais para cada polígono criado na segmentação. Após a extração dos atributos, foi realizada a coleta de amostras que se concentrou em 4 (quatro) classes de uso e cobertura do solo. A exceção foi o ano de 2010, onde se acrescentou as classes “Nuvens” e “Sombra” para complementar a cobertura do solo, quantificadas nos Quadros 10.

Quadro 10 - Quantidade de amostras por classe.

Classe	Landsat 5	Landsat 8	Landsat 8	CBERS 4A
---------------	------------------	------------------	------------------	-----------------

	(2010)	(2016)	(2018)	(2021)
Área antropizada	12	30	31	07
Hidrografia	04	22	16	08
Garimpo	-	71	40	50
Vegetação	10	39	05	10
Nuvens	20	-	-	-
Sombra	18	-	-	-

Fonte: A autora (2022).

Foi executada a classificação utilizando o algoritmo C5.0, onde utilizou-se todos os atributos de cada segmentação, e como parâmetro teve-se 30% das amostras para a validação e 70% para o treinamento. E por fim, foi realizado o processo de converter o arquivo resultante da classificação, arquivo vetorial, para o formato raster, com o objetivo de facilitar a criação dos modelos.

4.3.5.3 Validação

A validação teve como objetivo propiciar uma boa avaliação da acurácia temática, sendo assim, foram geradas as matrizes de confusão de cada classificação, com os cruzamentos das classes reais e as mapeadas.

Para complementar a validação, foram geradas o índice Kappa e a exatidão global de cada classificador.


4.3.5.4 Pós-Classificação

Após a classificação, foi aplicado um filtro de mediana 3x3, através da ferramenta *Focal Analysis* do software *Erdas Imagine*, a fim de eliminar a presença de ruídos.

4.3.6 Análise e processamento dos dados secundários

Após a coleta dos dados secundários, foi necessário realizar alguns ajustes (Figura 11) nos dados para padronizar todos os insumos para a classificação baseada em conhecimento. Então, o primeiro passo foi recortar os arquivos para a área analisada, e em seguida todos os dados foram projetados para SIRGAS2000/UTM zona 21S.

Figura 11 - Fluxograma metodológico da etapa de análise e processamento dos dados secundários.



Fonte: A autora (2022).

Os arquivos vetoriais reprojados foram convertidos para o formato matricial, com valores inteiros, com o objetivo de facilitar a classificação baseada em conhecimento. Assim, onde há a presença do dado, retornará o valor correspondente a classe de interesse.

4.3.7 Classificação baseada em conhecimento

Os modelos de classificação baseados em conhecimento foram construídos a partir dos dados auxiliares secundários e dos dados auxiliares gerados anteriormente (índices espectrais e classificação supervisionada), para cada ano, utilizando-se regras para cada classe analisada. Considerando que cada alvo possui valores espectrais diferentes, foi analisada cada classe com sua particularidade. Ao todo foram gerados cinco modelos de classificação baseada em

conhecimento. Utilizando o índice kappa, avaliou-se qual modelo melhor representou a área analisada.

O Modelo 01, apresentado na Tabela 2, teve como foco principal a aplicação da classificação GEOBIA em todas as classes.

Tabela 2 – Dados e regras utilizadas no Modelo 01.

Classe	Dados	Regras
Vegetação	NDVI	NDVI > 0,66
	MapBiomas	MapBiomas = classe Formação Florestal
	GEOBIA	MapBiomas = classe Formação Savânica
		GEOBIA = classe Vegetação
Garimpo	NDVI	NDVI ≤ 0
	MapBiomas	MapBiomas = classe Mineração
	GEOBIA	GEOBIA = classe Garimpo
Hidrografia	NDWI	NDWI > 0
	MapBiomas	Mapbiomas = classe Corpo D'água
	GEOBIA	MapBiomas = classe Rio Lago e Oceano
		GEOBIA = classe Hidrografia
Área antropizada	MapBiomas	MapBiomas = classe Agropecuária, Pastagem, Agricultura e Mosaico de Agricultura e Pastagem
	PRODES	PRODES = 1
	GEOBIA	GEOBIA = classe de Área antropizada

Fonte: A autora (2022).

O Modelo 02, Tabela 3, teve como objetivo analisar a aplicação do algoritmo *Random Forest* na classificação baseada em conhecimento.

Tabela 3 – Dados e regras utilizadas no Modelo 02.

Classe	Dados	Regras
Vegetação	NDVI	NDVI > 0,66
	MapBiomas	MapBiomas = classe Formação Florestal
	<i>Random Forest</i>	MapBiomas = classe Formação Savânica
		<i>Random Forest</i> = classe Vegetação
Garimpo	NDVI	NDVI ≤ 0
	MapBiomas	MapBiomas = classe Mineração
	<i>Random Forest</i>	<i>Random Forest</i> = classe Garimpo
Hidrografia	NDWI	NDWI > 0
	MapBiomas	Mapbiomas = classe Corpo D'água
	<i>Random Forest</i>	MapBiomas = classe Rio Lago e Oceano
		<i>Random Forest</i> = classe Hidrografia

Área antropizada	MapBiomas PRODES <i>Random Forest</i>	MapBiomas = classe Agropecuária, Pastagem, Agricultura e Mosaico de Agricultura e Pastagem PRODES = 1 <i>Random Forest</i> = classe de Área antropizada
------------------	---	--

Fonte: A autora (2022).

O Modelo 03, Tabela 4, analisou a interferência do algoritmo *Support Vector Machine* na classificação baseada em conhecimento.

Tabela 4 - Dados e regras utilizadas no Modelo 03.

Classe	Dados	Regras
Vegetação	NDVI	NDVI > 0,66
	MapBiomas	MapBiomas = classe Formação Florestal
	<i>Support Vector Machine</i>	MapBiomas = classe Formação Savânica
		<i>Support Vector Machine</i> = classe Vegetação
Garimpo	NDVI	NDVI =< 0
	MapBiomas	MapBiomas = classe Mineração
	<i>Support Vector Machine</i>	<i>Support Vector Machine</i> = classe Garimpo
Hidrografia	NDWI	NDWI > 0
	MapBiomas	Mapbiomas = classe Corpo D'água
	<i>Support Vector Machine</i>	MapBiomas = classe Rio Lago e Oceano
		<i>Support Vector Machine</i> = classe Hidrografia
Área antropizada	MapBiomas	MapBiomas = classe Agropecuária, Pastagem, Agricultura e Mosaico de Agricultura e Pastagem
	PRODES	PRODES = 1
	<i>Support Vector Machine</i>	<i>Support Vector Machine</i> = classe de Área antropizada

Fonte: A autora (2022).

O Modelo 04 consistiu na utilização dos três modelos de classificação, o GEOBIA, RF e SVM, mantendo os outros insumos como padrão, assim como nos modelos anteriores.

Para o Modelo 05 a análise foi feita de forma particular, analisando a relevância de cada insumo para cada classe (Tabela 5). Para a classe Área Antropizada, foi analisado que os índices espectrais, os algoritmos RF e SVM não possuem relevância para esta classe, e que a junção dos dados PRODES e a classe Pastagem do MapBiomas, possuem maior influência para o alvo.

Tabela 5 – Dados e regras utilizadas no Modelo 05.

Classe	Dados	Regras
Vegetação	NDVI	NDVI > 0,2
	MapBiomas	MapBiomas = classe Formação Florestal
	<i>Random Forest</i>	<i>Random Forest</i> = classe Vegetação

	<i>Support Vector Machine</i>	<i>Support Vector Machine</i> = classe Vegetação
Garimpo	MapBiomas	MapBiomas = classe Mineração
	GEOBIA	GEOBIA = classe Garimpo
	<i>Random Forest</i>	<i>Random Forest</i> = classe Garimpo
	<i>Support Vector Machine</i>	<i>Support Vector Machine</i> = classe Garimpo
Hidrografia	MapBiomas	MapBiomas = classe Rio Lago e Oceano
Área antropizada	MapBiomas	MapBiomas = classe Pastagem
	PRODES	PRODES = 1

Fonte: A autora (2022).

A classe Hidrografia utilizou como testes iniciais os dados NDWI, MapBiomas, os algoritmos de classificação RF e SVM, e a classificação GEOBIA. No primeiro teste houve confusão do NDWI com as áreas de garimpo, sendo assim, o índice foi dispensado nesta classe, assim como, posteriormente em outros testes, os classificadores. Sendo assim foram utilizados apenas os dados MapBiomas de código 33 que correspondem a Rio, Lago e Oceano.

Para a classe Garimpo, inicialmente utilizou-se o índice espectral NDWI, com valores superiores a 0, ou seja, valores que representam a presença de áreas úmidas, e NDVI, com valores inferiores a 0.2, mas não houve relevância para esta classe. Então utilizou-se os classificadores RF, SVM e GEOBIA correspondente a áreas de garimpo, e o dado MapBiomas, correspondendo a áreas de mineração.

A classe Vegetação teve como insumos iniciais, o índice NDVI, com valores superiores de 0.66, o MapBiomas com o código 3 e 12, representando as classes Formação Florestal e Formação Campestre, respectivamente. E por fim os classificadores RF, SVM e GEOBIA com o código 4, representando a vegetação. Após vários testes visuais, chegou-se ao modelo que melhor representou esta classe, sendo o NDVI com valores superiores a 0.2, o código 3 do MapBiomas, e o código 4 dos classificadores RF e SVM.

Para saber qual modelo de classificação foi o mais eficaz para o mapeamento de áreas de atividades garimpeiras, aplicou-se o método de avaliação da classificação, segundo Congalton e Green (1999), o índice Kappa.


5. RESULTADOS

Neste tópico serão apresentados os resultados obtidos utilizando os procedimentos metodológicos estabelecidos.

5.1 PRÉ-PROCESSAMENTO DE IMAGENS

Na Figura 12 é possível analisar o efeito da aplicação da correção atmosférica em dados do satélite Landsat 5 (2010) para a área piloto. A atmosfera interage com a radiação eletromagnética, gerando consideráveis alterações do fluxo radiante oriundo do alvo. Os principais indícios desses efeitos sobre a imagem são a redução do brilho da superfície em regiões espectrais específicas. Assim, a análise de imagens deve levar em consideração as características espectrais do sensor e as condições atmosféricas da data e hora da aquisição desses dados (Freire, 2002).

Figura 12 – Imagem Landsat 5/TM para o ano de 2010: a) sem correção atmosférica e b) com correção atmosférica.



Fonte: a autora (2022).


5.2 GERAÇÃO DE DADOS AUXILIARES

Neste tópico serão apresentados os resultados dos dados auxiliares gerados.

5.2.1 Índices espectrais


Nesta etapa são apresentados os resultados dos índices espectrais para cada ano de análise para a área piloto. Na Figura 13 a 16 é apresentado o índice espectral NDVI para cada ano, respectivamente, e na Figura 17 a 20 o índice NDWI para os anos de 2010, 2016, 2018 e 2021.

Figura 13 - Mapa do índice NDVI para o ano de 2010.




Fonte: a autora (2021).

Figura 14 - Mapa do índice NDVI para o ano de 2016.




Fonte: a autora (2022).

Figura 15 - Mapa do índice NDVI para o ano de 2018.




Fonte: a autora (2022).

Figura 16 - Mapa do índice NDVI para o ano de 2021.




Fonte: a autora (2022).

Figura 17 - Mapa do índice NDWI para o ano de 2010.




Fonte: a autora (2022).

Figura 18 - Mapa do índice NDWI para o ano de 2016.




Fonte: a autora (2022).

Figura 19 - Mapa do índice NDWI para o ano de 2018.



Fonte: a autora (2022).

Figura 20 - Mapa do índice NDWI para o ano de 2021.



Fonte: a autora (2022).


5.2.2 Classificação de imagens

Nesta seção encontram-se os resultados referentes ao método GEOBIA, e às classificações RF e SVM.

5.2.2.1 Classificação GEOBIA


Na Figura 21 a 24 tem-se o resultado obtido através da Classificação GEOBIA para os anos de 2010, 2016, 2018 e 2021, respectivamente.

Figura 21 - Classificação GEOBIA para o ano de 2010.




Fonte: Autora (2022).

Figura 22 - Classificação GEOBIA para o ano de 2016.




Fonte: Autora (2022).

Figura 23 - Classificação GEOBIA para o ano de 2018.



Fonte: Autora (2022).

Figura 24 - Classificação GEOBIA para o ano de 2021.



Fonte: Autora (2022).

A árvore de decisão gerada para o ano de 2010 fez-se a leitura de 46 amostras de treinamento. A árvore não apresentou erro (confusão) nas amostras de treinamento entre as classes.

O resultado para o ano de 2016 obteve-se o treinamento de 116 amostras. A árvore de decisão apresentou um erro de 0,9%, ou seja, das amostras de treinamento apenas 1 (uma) da classe garimpo teve confusão com a classe vegetação.

O ano de 2018 obteve 127 amostras de treinamento. O erro apresentado foi de 6,3%, pois houve bastante confusão na classe “AreaAntropizada” e na classe “Garimpo”.

Por último, o ano de 2021 obteve 51 amostras de treinamento. Apresentou um erro de 20,8% na matriz de confusão, onde a classe “AreaAntropizada” mais confundiu com as demais classes.

A matriz de confusão para o ano de 2021, como apresentada na Tabela 6, foi gerada utilizando 110 amostras dentre as classes utilizadas na classificação. O índice Kappa apresentou um excelente resultado para o ano de 2021 com 0,94, e a acurácia global de 0,99.

Tabela 6 - Matriz de confusão do ano de 2021.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	18	0	2	0
Hidrografia	0	18	2	0
Garimpo	0	0	50	0
Vegetação	0	0	0	20

Fonte: Autora (2022).

5.2.2.2 Classificação RF

A classificação *Random Forest*, Figura 25 a 28, gerou os seguintes resultados para os anos de 2010, 2016, 2018 e 2021. O ano de 2010 teve 240 amostras, como mostrado na Tabela 7.

Tabela 7 - Matriz de confusão do ano de 2010.

	Área antropizada	Hidrografia	Garimpo	Vegetação	Nuvem	Sombra
--	------------------	-------------	---------	-----------	-------	--------

Área antropizada	34	0	9	6	0	0
Hidrografia	0	31	1	0	0	0
Garimpo	2	0	18	0	1	0
Vegetação	6	1	1	63	0	0
Nuvem	0	0	1	0	46	0
Sombra	0	2	0	0	1	17

Fonte: Autora (2022).

Os dados referentes ao ano de 2016 geraram 180 amostras de validação (Tabela 8).

Tabela 8 - Matriz de confusão do ano de 2016.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	45	0	7	2
Hidrografia	0	37	2	0
Garimpo	2	5	65	0
Vegetação	4	0	0	33

Fonte: Autora (2022).

Os dados do ano de 2018 geraram 263 amostras de validação (Tabela 9).

Tabela 9 - Matriz de confusão do ano de 2018.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	49	2	0	0
Hidrografia	1	72	0	1
Garimpo	0	3	79	2
Vegetação	0	1	3	50

Fonte: Autora (2022).

O ano de 2021 usou 195 amostras de validação (Tabela 10).

Tabela 10 - Matriz de confusão do ano de 2021.

	Área antropizada	Hidrografia	Garimpo	Vegetação
--	------------------	-------------	---------	-----------

Área antropizada	41	1	1	3
Hidrografia	0	39	7	0
Garimpo	1	2	44	0
Vegetação	4	2	0	50

Fonte: Autora (2022).


O resultado do índice *Kappa* para cada ano está descrito na Tabela 11.

Tabela 11 – Resultado do índice Kappa do algoritmo Random Forest.

Ano	Índice Kappa
2010	0,84
2016	0,85
2018	0,93
2021	0,87


Fonte: Autora (2022).

Figura 25 - Classificação Random Forest para o ano de 2010.




Fonte: Autora (2022).

Figura 26 - Classificação Random Forest para o ano de 2016.




Fonte: Autora (2022).

Figura 27 - Classificação Random Forest para o ano de 2018.



Fonte: Autora (2022).

Figura 28 - Classificação Random Forest para o ano de 2021.



Fonte: Autora (2022).

5.2.2.3 Classificação SVM

A classificação *Support Vector Machine*, Figura 29 a 32, gerou os seguintes resultados para os anos de 2010, 2016, 2018 e 2021. O ano de 2010 teve 240 amostras, como mostrado na Tabela 12.

Tabela 12 - Matriz de confusão do ano de 2010.

	Área antropizada	Hidrografia	Garimpo	Vegetação	Nuvem	Sombra
Área antropizada	33	0	7	4	0	0
Hidrografia	0	32	1	0	0	0
Garimpo	2	0	19	0	0	0
Vegetação	7	0	2	65	0	0
Nuvem	0	0	1	0	47	0
Sombra	0	2	0	0	1	17

Fonte: Autora (2022).

O ano de 2016 gerou 253 amostras de validação (Tabela 13).

Tabela 13 - Matriz de confusão do ano de 2016.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	95	0	2	0
Hidrografia	0	28	1	0
Garimpo	3	3	61	1
Vegetação	0	0	0	59

Fonte: Autora (2022).

O ano de 2018 gerou 263 amostras de validação (Tabela 14).

Tabela 14 - Matriz de confusão do ano de 2018.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	50	0	0	0

Hidrografia	0	75	0	1
Garimpo	0	1	82	1
Vegetação	0	2	0	51

Fonte: Autora (2022).

O ano de 2021 usou 220 amostras de validação (Tabela 15).

Tabela 15 - Matriz de confusão do ano de 2021.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	52	0	1	7
Hidrografia	0	46	4	0
Garimpo	0	1	51	1
Vegetação	3	0	0	54

Fonte: Autora (2022).


O resultado do índice *Kappa* para cada ano está descrito na Tabela 16.

Tabela 16 - Resultado do índice Kappa do algoritmo Support Vector Machine.

Ano	Índice Kappa
2010	0,86
2016	0,94
2018	0,97
2021	0,90


Fonte: Autora (2022).

Figura 29 - Classificação Support Vector Machine para o ano de 2010.




Fonte: Autora (2022).

Figura 30 - Classificação Support Vector Machine para o ano de 2016.




Fonte: Autora (2022).

Figura 31 - Classificação Support Vector Machine para o ano de 2018.



Fonte: Autora (2022).

Figura 32 - Classificação Support Vector Machine para o ano de 2021.




Fonte: Autora (2022).

5.3 CLASSIFICAÇÃO BASEADA EM CONHECIMENTO


Para a classificação baseada em conhecimento foram gerados cinco modelos utilizando os dados gerados e os secundários. O modelo que melhor representou o uso e cobertura do solo foi selecionado através da análise visual da classificação (Figura 33 a 37) e o índice kappa com maior resultado (Tabela 22).

Figura 33 - Comparação entre o Google Earth e o resultado do Modelo 01 para as regiões A e B.




Fonte: Autora (2022).

Figura 34 - Comparação entre o Google Earth e o resultado do Modelo 02 para as regiões A e B.




Fonte: Autora (2022).

Figura 35 - Comparação entre o Google Earth e o resultado do Modelo 03 para as regiões A e B.




Fonte: Autora (2022).

Figura 36 - Comparação entre o Google Earth e o resultado do Modelo 04 para as regiões A e B.



Fonte: Autora (2022).

Figura 37 - Comparação entre o Google Earth e o resultado do Modelo 05 para as regiões A e B.



Fonte: Autora (2022).

Analisando as Figura 33 a 37 é possível afirmar que o modelo 1 não apresentou todos os alvos da região A, gerando como resultado apenas algumas áreas de garimpo, na região B não houve representação total da atividade garimpeira apresentada na imagem referência (Google Satellite). Nos modelos 2 e 3, é possível observar que houve confusão entre as classes nos dois cenários, deixando a classificação bastante ruidosa. O modelo 4 resultou em várias áreas sem dados, deixando assim o modelo insuficiente para a classificação. O modelo 5 obteve o melhor resultado visualmente, sem a presença de ruídos e com a delimitação fiel aos alvos existentes na área.

A análise estatística dos modelos foi realizada utilizando a matriz de confusão e gerando o índice kappa (Tabela 22), para assim complementar a escolha do melhor modelo.

O modelo 1 utilizou de 210 amostras para gerar a matriz de confusão (Tabela 17). É possível analisar que o modelo apresentou confusão considerável da classe Garimpo com as classes Hidrografia e Área antropizada.

Tabela 17 - Matriz de confusão do modelo 1.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	26	0	29	0
Hidrografia	0	11	37	2
Garimpo	1	0	59	0
Vegetação	2	0	0	48

Fonte: Autora (2022).

Foram utilizadas 190 amostras no modelo 2, resultando na Tabela 18. Todas as classes tiveram confusão, sendo que a Vegetação foi a que mais confundiu com as demais classes.

Tabela 18 - Matriz de confusão do modelo 2.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	20	0	1	9
Hidrografia	0	6	10	34
Garimpo	3	6	38	13

Vegetação	4	0	0	46
-----------	---	---	---	----

Fonte: a autora (2022).

O modelo 3, Tabela 19, apresentou bastante confusão da Vegetação com as demais classes, assim como o Garimpo confundiu com a Hidrografia.

Tabela 19 - Matriz de confusão do modelo 3.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	13	2	3	6
Hidrografia	0	7	9	10
Garimpo	10	10	43	5
Vegetação	3	0	1	35

Fonte: a autora (2022).

No modelo 4, foram utilizadas 154 amostras, resultando na matriz de confusão, como apresentado na Tabela 20. Todas as classes tiveram confusão considerável com a classe Garimpo.

Tabela 20 - Matriz de confusão do modelo 4.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	30	0	0	0
Hidrografia	0	15	10	0
Garimpo	7	6	51	3
Vegetação	0	0	0	32

Fonte: a autora (2022).

A Tabela 21 apresenta a matriz de confusão resultante de 370 amostras para o modelo 5. É possível analisar que a classe Área antropizada teve confusão com a classe Garimpo, a classe Hidrografia confundiu com a classe Garimpo, a classe Garimpo teve pequena confusão com a Área antropizada, e a Vegetação confundiu com as classes Área antropizada e Hidrografia.

Tabela 21 - Matriz de confusão do modelo 5.

	Área antropizada	Hidrografia	Garimpo	Vegetação
Área antropizada	96	0	2	2
Hidrografia	0	17	0	3
Garimpo	4	5	141	0
Vegetação	0	0	0	100

Fonte: a autora (2022).


Então, o modelo mais eficaz apresentado, tanto visualmente como no índice kappa, foi o modelo 5, apresentando um kappa de 0,94. Utilizando o modelo 5, foi gerada a classificação da área de estudo para o ano de 2010 como apresentado na Figura 38, o ano de 2016 apresentado na Figura 39, o ano de 2018 (Figura 40) e o ano de 2021 na Figura 41.

Tabela 22 - Resultado do índice Kappa dos modelos.

Modelo	Índice Kappa
01	0,56
02	0,39
03	0,47
04	0,76
05	0,94


Fonte: Autora (2022).

Figura 38 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2010.




Fonte: a autora (2022).

Figura 39 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2016.




Fonte: a autora (2022).

Figura 40 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2018.



Fonte: a autora (2022).

Figura 41 - Resultado da aplicação do modelo 5 para a área de estudo no ano de 2021.




Fonte: a autora (2022).

5.4 MAPEAMENTO DAS ÁREAS DE GARIMPO


O mapeamento das áreas de garimpo foi gerado através da classificação baseada em conhecimento para cada ano analisado: 2010 (Figura 43), 2016 (Figura 44), 2018 (Figura 45) e 2021 (Figura 46). Após a obtenção da área em hectares (Quadro 11), foi possível analisar o aumento de atividade garimpeira ao nordeste da Terra Indígena Munduruku (Figura 42). É possível analisar que em cada ano a área de garimpo teve um aumento significativo entre os anos de 2010 e 2018, e o aumento de 2018 para 2021 foi de aproximadamente cinco vezes mais que nos anos seguintes (Figura 47).

Figura 42 - Mapeamento das áreas de garimpo nos anos de 2010,2016,2018 e 2021.




Fonte: a autora (2022).

Figura 43 - Mapeamento das áreas de garimpo nos anos de 2010.




Fonte: a autora (2022).

Figura 44 - Mapeamento das áreas de garimpo nos anos de 2016.




Fonte: a autora (2022).

Figura 45 - Mapeamento das áreas de garimpo nos anos de 2018.



Fonte: a autora (2022).

Figura 46 - Mapeamento das áreas de garimpo nos anos de 2021




Fonte: a autora (2022).

Quadro 11 - Área de garimpo em hectares para cada ano.

Ano analisado	Área de garimpo (ha)	Taxa de crescimento (%)
2010	45,0000	-
2016	741,4360	1548
2018	1.228,3950	66
2021	7.686,0360	526

Fonte: a autora (2022).

Figura 47 - Áreas de garimpo (hectare/ano).



Fonte: a autora (2022).

6. DISCUSSÕES

Nos modelos que possuem o índice espectral NDWI observa-se confusão entre as classes Garimpo e Hidrografia, dificultando a análise da área. Isso ocorre devido a presença de lagoas com rejeitos geradas comumente nas áreas de garimpo. Já no modelo escolhido como o mais eficaz para a classificação, temos a não utilização do índice espectral NDWI, de forma a evitar tal confusão. Simionato (2019) encontrou resultados semelhantes na utilização do NDWI com um desempenho mais satisfatório na discriminação do uso e cobertura do solo que envolve atividades garimpeiras.

Para o modelo selecionado realizou-se a análise classe a classe, observando em quais regras apresentam uma melhor resposta da classificação. Assim, para a classe Vegetação obteve-se melhor resposta utilizando o índice espectral NDVI em conjunto com as classificações MapBiomas, *Random Forest* e *Support Vector Machine*. Para a classe Garimpo a melhor resposta foi através das classificações MapBiomas, *Random Forest* e *Support Vector Machine*. Na Hidrografia, apenas o MapBiomas apresenta um resultado satisfatório. Na Área Antropizada aplicou-se a classificação MapBiomas e o dado secundário PRODES.

Comparando as áreas de garimpo existentes em cada ano, há um grande crescimento (Figura 47). Em 2010 as áreas de atividade garimpeira somam 45 hectares. Já no ano de 2016, há uma área de mais de 700 hectares transformados em atividade garimpeira, o que corresponde a um crescimento de mais de 15 vezes a área de 2010, ou seja, 1.546,7%. De 2016 para 2018, há um crescimento de 66%. De 2018 para 2021, o crescimento é de 525%, ou seja, mais de cinco vezes o valor de 2018 é acrescido em 3 anos. Considerando de 2016 para 2021, o crescimento é de 936,6%, ou seja, em cinco anos as áreas contendo atividade garimpeira na região há um aumento de quase dez vezes.

De acordo com o Projeto MapBiomas (2021), houve uma grande expansão na área de mineração comparando os anos de 1985 e 2020, saltando de 31 mil hectares para 206 mil hectares de atividade garimpeira no Brasil. Em 2020, as ocorrências de atividade garimpeira dentro de áreas indígenas totalizam 9,3% das áreas de garimpo no Brasil, dentre elas está a Terra Indígena Munduruku. O resultado encontrado neste trabalho para o período entre 2010 e 2021 corrobora com o encontrado por Projeto MapBiomas (2021), demonstrando a expansão da atividade garimpeira em Terras Indígenas.

7. CONCLUSÕES

O presente trabalho buscou desenvolver modelos em conjunto com técnicas de processamento digital de imagens para classificação de uso e cobertura da terra utilizando integração multisensores e, posteriormente, avaliar qual o modelo mais eficaz para o mapeamento de atividade garimpeira. De acordo com o que foi apresentado e discutido neste trabalho, pôde-se avaliar e responder os objetivos propostos.

Para chegar no objetivo de mapear as áreas degradadas oriundas de atividade garimpeira na região da Terra Indígena Munduruku foram definidos dois objetivos específicos. O primeiro foi desenvolver um modelo baseado em conhecimento mais eficaz para a classificação de áreas de garimpo, onde definiu-se um modelo que, a princípio, foi resultado da análise visual da relevância dos insumos para cada classe. Para a Área Antropizada o melhor resultado foi obtido aliando os dados PRODES e MapBiomas. Para a Hidrografia, a utilização única dos dados MapBiomas apresentou resultado satisfatório para a delimitação dos córregos e rios. Para a classe Garimpo, foram utilizados os dados MapBiomas e os classificadores RF, SVM e GEOBIA. Para a vegetação, o melhor resultado foi obtido com a utilização dos dados NDVI, MapBiomas e os classificadores RF, SVM e GEOBIA. A avaliação dos resultados foi pautada na utilização do índice kappa.

O segundo objetivo proposto neste trabalho é mapear a expansão de áreas degradadas pela atividade de garimpo durante os anos de 2010 a 2021. Foram encontrados resultados que indicam uma expansão exorbitante da atividade garimpeira, com principal aumento entre os anos de 2018 e 2021.

REFERÊNCIAS

ALVES, F. C.; FRAGAL, E. H. **Avaliação dos Algoritmos MAXVER e SVM na Classificação da Cobertura Vegetacional da Planície de Inundação do Alto Rio Paraná.** In: Encontro Estadual de Geografia e Ensino, II, e Semana de Geografia, XX, 2011, Maringá. Anais...Maringá: 2011. p.0621-0632.

AMORAS, W. W. **A garimpagem na Amazônia: doenças, desordem e descaso. uma visão do garimpo do Crepori (PA).** Dissertação (Mestrado no Núcleo de Altos Estudos Amazônicos) – Universidade Federal do Pará, Belém, 1991.

ARAÚJO, E. S. **Projeto especial Província Mineral do Tapajós PROMIN Tapajós.** CPRM - Serviço Geológico do Brasil. Brasília, 2000. Disponível em: <<https://rigeo.cprm.gov.br/handle/doc/8484>>. Acesso em 10 jun. 2022

BARRETO, M. L.; SIROTTEAU, G. N. C. **Mineração em terras indígenas: um estudo comparativo.** In: Ensaio sobre a sustentabilidade da mineração no Brasil. Rio de Janeiro: CETEM/MCT, 2001. p.84-107. ISBN: 85-7227-161-9.

BOXER, C.R. **A idade de ouro do Brasil: Dores de crescimento de uma sociedade colonial.** Tradução: N. Lacerda. 2. ed. rev. São Paulo: Companhia Editora Nacional, 1969. 407 p. v. 341. Disponível em: <https://bdor.sibi.ufrj.br/bitstream/doc/388/1/341%20PDF%20-%20OCR%20-%20RED.pdf>. Acesso em: 1 jul. 2021

BRASIL. **Programa Nacional de Atividades Espaciais.** MCT/AEB, Brasília, 2005.

BREIMAN, L. **Random Forests.** Kluwer Academic Publishers, [s. l.], v. 45, p. 5-32, 2001. DOI 10.1023/a:1010933404324

BRENNER, V.C.; GUASSELLI, L.A. **Índice de diferença normalizada da água (NDWI) para identificação de meandros ativos no leito do canal do rio Gravataí/RS–Brasil.** In:

SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO-SBSR, 17, João Pessoa-PB, Brasil, 2015, Anais, 25: 3693-3699. 2015

BRITES, R.S.; SOARES, V.P.; RIBEIRO, C.A.A.S. **Comparação de Desempenho entre Três Índices de Exatidão Aplicados a Classificações de Imagens Orbitais**. Anais VIII Simpósio Brasileiro de Sensoriamento Remoto, Salvador, Brasil, p. 813-821, abr 1996. Disponível em: <<http://marte.sid.inpe.br/col/sid.inpe.br/deise/1999/02.01.15.33/doc/T51.pdf>>. Acesso em: 13 jul. 2021.

BRITO, D; BRUSEKE, F; MATHIS, A. **Riqueza Volátil: a mineração de ouro na Amazônia**. Belém: Cejup, 1997.

BÜCKNER, J.; PAHL, M.; STAHLHUT, O.; LIEDTKE, C.E. **GeoAIDA - A Knowledge Based Automatic Image Data Analyser for Remote Sensing Data**. Institut für Theoretische Nachrichtentechnik und Informationsverarbeitung, Hannover, Germany, ed. 2, 2000. Disponível em: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.20.5785&rep=rep1&type=pdf>. Acesso em: 19 jul. 2021.

BURKHALTER, S. B. **Amazon Gold Rush: Markets and the Mundurucu Indians**. 1982. Tese (Doutorado em Filosofia) - Columbia University, [S. l.], 1982. Disponível em: <<http://biblioteca.funai.gov.br/media/pdf/TESES/MFN-1123.PDF>>. Acesso em: 10 jul. 2021.

CARVALHO, A.; MORAES NETO, J. M. **Estudo da degradação ambiental da Bacia hidrográfica do açude Soledade no Estado da Paraíba**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO – SBSR. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE.

CHAKURE, A. Random Forest Regression. Medium, 2019. Disponível em: <<https://medium.com/swlh/random-forest-and-its-implementation-71824ced454f>>. Acesso em: 08 jun 2022.

COHEN J. A. **Coefficient of agreement for nominal scales**. Journal of Educational and Measurement, v.20, n.1, p.37-46, 1960.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Lewis Publishers, Boca Raton, FL, 1999.

CORDANI, U. G.; JULIANI, C. **Potencial mineral da Amazônia: problemas e desafios**. *REB: Revista de Estudios Brasileños*, Madrid, v. 6, n. 11, p. 91-108, 2019. Disponível em: < <https://doi.org/10.14201/reb201961191108> > DOI: 10.14201/reb201961191108.

CASTILLA, G.; HAY, G. J. ***Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline***. *Object-Based Image Analysis Spatial Concepts for Knowledge-Driven Remote Sensing Applications* p.75.2008.

COSTA, L. R. **Homens de ouro: Trabalho e Conhecimento entre os Garimpeiros Clandestinos de Ouro da Região de Mariana**. Tese (Mestrado em Extensão Rural) - Programa de Pós-Graduação em Extensão Rural, Universidade Federal de Viçosa. Viçosa, p.135.2002.

COSTA, L. R. **Os garimpos clandestinos de ouro em Minas Gerais e no Brasil: tradição e mudança**. *História & Perspectivas*, Uberlândia, v. 3637, ed. 1, p. 247-279, jan. dez 2007.

CURI, M. V. **A mineração e o estatuto do índio**. In: CURI, Melissa Volpato. *Mineração em terras indígenas: caso terra indígena Roosevelt*. Orientador: Hildebrando Herrmann. 2005. Dissertação (Mestrado em Geociências) - Universidade Estadual de Campinas, Instituto de Geociências., Campinas - SP, 2005.

DA SILVA, M. A. R. **Mineração no Pará: elementos para uma estratégia de desenvolvimento regional**. Governo do Estado do Pará, Secretaria de Estado e Indústria, Comércio e Mineração. Belém, 1994.

DIMENSTEIN, G. **Meninas da Noite: a prostituição de meninas escravas no Brasil**. São Paulo: Ática, 1992.

DINIZ, J. M. F. S. **Avaliação do Potencial dos Dados Polarimétricos Sentinel-1A para Mapeamento do Uso e Cobertura da Terra na Região de Ariquemes - RO**. 2019. 162p.Dissertação. Instituto Nacional de Pesquisas Espaciais (INPE). São José dos Campos.2019.

DOURADO, M. C. C. O. C. **Meio Ambiente do Pará: fato e norma**. Belém: Numa/UFPA, 1993.

EXELIS. HARRIS GEOSPATIAL SOLUTIONS. **Support vector machine background**. 2015. Disponível em: <<https://www.l3harrisgeospatial.com/docs/backgroundsvm.html>>. Acesso em: 20 jul. 2021.

FEITOSA, J. R. P.; FILHO, J. F.C.; SILVA, B. B. da. **Avaliação de índices de vegetação em área irrigada do sub-médio** São Francisco, Petrolina-PE, In: Congresso Brasileiro de Meteorologia, 18, Fortaleza, 2004.

FIOCRUZ. **Avaliação da exposição ambiental ao mercúrio proveniente da atividade garimpeira de ouro na terra indígena Yanomami, Roraima, Amazônia, Brasil**. 2016. Disponível em https://www.socioambiental.org/sites/blog.socioambiental.org/files/diagnostico_contaminacao_mercurio_terra_indigena_yanomami.pdf. Acesso em 15 jul. 2021.

FITZ, P.R. **Geoprocessamento sem complicação** - São Paulo, SP: Oficina de Textos, 2008.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002. p.97.

FOODY, G. M. **Status of land cover classification accuracy assessment**. Remote Sensing of Environment, v. 80, p. 185– 201, 2002.

FREIRE, M.L.F. **Correção atmosférica em imagens LANDSAT contaminadas por efeito de adjacência**. Dissertação de Mestrado em Meteorologia, Universidade Federal da Paraíba, Campina Grande, 98p.,2002.

FUNAI. **Levantamento Etnoecológico Munduruku - Terra Indígena Munduruku**. 2008. Disponível em: http://cggamgati.funai.gov.br/files/8314/8829/4911/munduruku_pt.pdf. Acessado em 22 jun. 2022.

FURTADO, H. S. **A Garimpagem do ouro e suas interfaces na Amazônia brasileira**. Revista Labirinto. Porto Velho-RO. V.32. 2020. p.242-261.

GONZALEZ, R.; WOODS, R. **Processamento de Imagens Digitais**. 3. ed. São Paulo: Edgard Blucher Ltda, 2000.

HARP (Indiana University). **Harp Support Vector Machine**. [S. l.], 2018. Disponível em: <https://dsc-spidal.github.io/harp/docs/examples/svm/>. Acesso em: 19 jul. 2021.

HEXAGON GEOSPATIAL. **ATCOR FOR IMAGINE: HAZE REDUCTION, ATMOSPHERIC AND TOPOGRAPHIC CORRECTION**. Disponível em: <https://www.geosystems.de/fileadmin/redaktion/Downloads/Produkte/ATCOR/ATCOR_Data_Sheet.pdf>. Acesso em: 13 jan. 2022.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo demográfico 2010**. Disponível em: <<http://www.ibge.gov.br/home/estatistica/populacao/censo2010/>>. Acesso em: 13 jul. 2021.

INPE - INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **CBERS 04A**. 2019. Disponível em: <<http://www.cbers.inpe.br/sobre/cbers04a.php>>. Acesso em: 13 jul. 2021

ISA - INSTITUTO SOCIOAMBIENTAL - **Garimpo na Terra Indígena Munduruku cresce 363% em 2 anos, aponta levantamento do ISA**. Disponível em: <<https://www.socioambiental.org/>>. Acesso em: 10 jun. 2022

LANDIS, J. R.; KOCH, G. G. **The measurements of observer agreement for categorical data**. *Biometrics*. v. 33, p. 159-174, 1977.

LATORRE, M; JÚNIOR, O.A.C.; CARVALHO, A.P.F.; SHIMABUKURO, Y.E., G. C. **Correção Atmosférica: Conceitos e Fundamentos**. *Revista Espaço e Geografia*. v. 5, n. 1, p. 153-178, 2002.

LIANG, Z.; JINPING, S.; HUIYOND, S.; GANG, Y.; YI, J. **Large area Land Cover Classification with LANDSAT ETM+ Images based on Decision Tree.**, 2012 [International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XXXIX-B7].

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. New York: John Wiley e Sons Inc., 1994, 708p.

LIMA, G. C. **Questão ambiental e educação: contribuições para o debate**. Revista Ambiente e Sociedade. v. 2, n. 5, p. 135-153, 1999.

MACEDO, O. G. de. **Avaliação de Classificadores em Imagens de Alta Resolução: Área urbana de Jaboatão dos Guararapes-PE**. Orientador: Prof^a Dr^a Ana Lúcia Bezerra Candeias. 2010. 85 f. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação) - Universidade Federal de Pernambuco, Recife, 2010. Disponível em: https://repositorio.ufpe.br/bitstream/123456789/2938/1/arquivo2032_1.pdf. Acesso em: 21 jul. 2021.

MATSUKUMA, C. K. **Análise comparativa de algoritmos de classificação não-supervisionada, no mapeamento do uso e cobertura do solo**. Dissertação (Mestrado) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba. 2002.

MELATTI, J. C. **Índios do Brasil**. EDUSP, São Paulo, 2007. Disponível em: <<https://pt.scribd.com/document/369996332/Indios-do-Brasil-Julio-Cesar-Melatti-pdf>>. Acesso em 20 jul 2021. ISBN 978-85-314-1013-0.

MEMON, A.A.; MUHAMMAD, S.; RAHMAN, S. e HAQ, M. **Flood monitoring and damage assessment using water indices: A case study of Pakistan flood-2012**. The Egyptian Journal of Remote Sensing and Space Science, 18(1): 99-106. 2015.

MONTEIRO, T; JERICÓ-DAMINELLO, C; SOUSA JÚNIOR, W. C; A bacia do rio Tapajós: caracterização e contexto socioambiental. In: SOUSA JÚNIOR (Org.). Tapajós: hidrelétricas, infraestrutura e caos. Elementos para a governança em uma região singular. São José dos Campos: ITA/CTA, 2014

MOREIRA, R. C. **Influência do posicionamento e da largura de bandas de sensores remotos e dos efeitos atmosféricos na determinação de índices de vegetação**. São José dos Campos, INPE, 2000. 181 p. (Dissertação de Mestrado).

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 3. ed. Viçosa: UFV, 2005. 320p

NEPOMUCENO, Í. T. R. . **Territórios munduruku e as tensões com garimpos e mineração no Alto e Médio Tapajós**. No prelo. In: Alfredo W. Berno de Almeida; Eriki Aleixo de Melo; Ítala Nepomuceno; Vinícius Cosmos Benvegnú. (Org.). *Mineração e garimpo em terras tradicionalmente ocupadas: conflitos sociais e mobilizações étnicas*. 1ed. Manaus: UEA Edições, 2019, v. , p. 65-75.

OOMMEN, T.; MISRA, D.; TWARAKAVI, N.K.C.; PRAKASH, A.; SAHOO, B.; BANDOPADHYAY, S. **An objective Analysis of Support Vector Machine Based Classification for Remote Sensing**. *Mathematical Geosciences*, v. 40, n. 4, p. 409-424, 2008. Disponível em: <<https://doi.org/10.1007/s11004-008-9156-6>> DOI: 10.1007/s11004-008-9156-6.

PEREIRA, A. C. L. **Garimpo e fronteira amazônica: as transformações dos anos 80**. In *Amazônia: fronteira agrícola 20 anos depois*. Belém: Museu Goeldi, 1991. pp.305-318.

Projeto MapBiomass – **Mapeamento da superfície de mineração industrial e garimpo no Brasil** - Coleção 6 - 2021, acessado em 22 jun 2022 através do link: https://mapbiomas-br-site.s3.amazonaws.com/Fact_Sheet_1.pdf.

RAMOS, A. R. A.; RODRIGUES, F. S. **O Garimpo Ilícito na Terra Indígena Yanomami entre a Cosmovisão Indígena e Ações Estatais**. *Unisul de Fato e de Direito: revista jurídica da Universidade do Sul de Santa Catarina*, [S.l.], v. 9, n. 16: 25-35, mai 2018. ISSN 2358-601X. Disponível em: http://www.portaldeperiodicos.unisul.br/index.php/U_Fato_Direito/article/view/5743/3737. Acesso em: 03 jul. 2021.

RIBEIRO, L.G.G.; IASBIK, T.A. **O Garimpo Ilegal e sua (In)Significância no Âmbito do Direito Penal Ambiental**. *Revista Argumentum – RA*, ISSN 2359-6889, Marília/SP, V. 20, N. 1, pp. 165-184, jan.-abr. 2019.

RICHARDS, J. A; JIA, X. Remote sensing digital image analysis. **Remote Sensing Digital Image Analysis**, p. 197, 2006. 27.

RODRIGUES, R. M. **O trabalho feminino no garimpo**. *Reforma Agrária*, 23 (3): 107-125. 1994.

SALOMÃO, E. P.; VEIGA, A. T. C. **Mineração. Presente e futuro da Amazônia**. Em Melfi, A. J., Misi, A., Campos, D. A.; Cordani, U.G.C. *Recursos Minerais no Brasil – Problemas e desafios* –, pp. 376-393. Rio de Janeiro: Academia Brasileira de Ciências, 2016

SHARMA, S. **Kernel Trick in SVM**: Kernel Trick is used to classify non-linear to linear using some Mathematical Concepts provided by Mercer's theorem.. [S. l.], 28 nov. 2019. Disponível em: <https://medium.com/analytics-vidhya/how-to-classify-non-linear-data-to-linear-data-bb2df1a6b781>. Acesso em: 20 jul. 2021.

SILVA, A. R. B. **Ouro do Pará: perdas técnicas, degradação e a marginalização do Estado na expansão industrial brasileira**. Anais do XXXV Congresso brasileiro de Geologia, 5: 2023-2030, Belém, 1988.

SIMIONATO, J. **Identificação de áreas de garimpo na Floresta Nacional do Crepori (Pará) através de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) e mineração de dados**. 2019. Trabalho de Conclusão de Curso (Graduação) - Curso de Geologia, Universidade Federal de Santa Catarina, 2019. Disponível em: <https://repositorio.ufsc.br/handle/123456789/204017>. Acessado em 22 jun 2022.

SOLUTIONS, I. V. I. **ENVI Feature Extraction Module User's Guide**. Feature Extraction Module Version 4.6, p. 26, Dezembro 2008. Disponível em: https://nanopdf.com/download/envi-feature-extraction-modile-users-guide_pdf. Acesso em: 11 jan 2022.

SOUZA, C. C.; DA CUNHA, M. C. **O uso das geotecnologias como ferramenta de auxílio na análise ambiental no município de Jataí-Goiás**. Geoambiente, n. 38, p. 151-174, 2020. Disponível em: <https://www.revistas.ufg.br/geoambiente/article/view/63586>. Acesso em: 20 jul 2021.

USGS, U.S. **Geological Survey**. Science for a changing world. [S. l.], 2021. Disponível em: <https://www.usgs.gov>. Acesso em: 18 jul. 2021.

VAPNIK, V.N. **The Nature of Statistical Learning Theory**. 2. ed. New York: Springer-Verlag, 1995. 332p.

VEGA, C. M; Orellana, J. D. Y; Oliveira, M. W; HACON, S. S.; BASTA, P. C. **Human Mercury Exposure in Yanomami Indigenous Villages from the Brazilian Amazon**. International Journal of Environmental Research and Public Health. Vol. 15,6 1051. 23 mai 2018. Disponível em <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6028914/>. Acesso em 17 jul. 2021. DOI:10.3390/ijerph15061051.

VEIGA, M. M.; SILVA, A. R. B.; HINTON, J. J. **O garimpo de ouro na amazônia: aspectos tecnológicos, ambientais e sociais.** In: Extração de ouro: princípios, tecnologia e meio ambiente. Cap.11. Rio de Janeiro: CETEM/MCT, 2002. p. 277-305.

WOLKMER, A.C. **Pluralismo jurídico: fundamentos de uma nova cultura do direito.** 4. ed. – São Paulo: Saraiva - 2015.