

APRENDIZADO DE MÁQUINA APLICADO NO MAPEAMENTO DO USO E COBERTURA DO SOLO DE ASSENTAMENTOS DE REFORMA AGRÁRIA NO ACRE.

MACHINE LEARNING APPLIED IN THE MAPPING OF LAND USE AND LAND COVER OF AGRARIAN REFORM SETTLEMENTS IN ACRE.

 Isabella Favero ^A
 José Marcato Júnior ^A
 Márcio Santos Araújo ^A
 Maurício de Souza ^A
 João Batista Sarmiento dos Santos Neto ^A
 Wesley Nunes Gonçalves ^A

^A Universidade Federal de Mato Grosso do Sul (UFMS), Campo Grande, MS, Brasil.

Recebido em: 16/06/2023 | 10/06/2024 DOI: 10.12957/tamoios.2024.77078

Correspondência para: Isabella Favero (isabella.favero@ufms.br)

Resumo

O conhecimento do uso e cobertura do solo auxilia na tomada de decisões no processo de regularização fundiária e no desenvolvimento do Plano Nacional de Reforma Agrária executado pelo INCRA, por meio das Superintendências Regionais em cada estado brasileiro. Neste estudo, investigamos a aplicação da técnica de aprendizado de máquina com o uso do algoritmo Suporte de Vetor de Máquina, combinado com imagens de satélite PlanetScope referente ao mês de outubro de 2022, para a classificação supervisionada do uso e cobertura do solo em 15 projetos de assentamentos no estado do Acre. Para o treinamento das amostras, definimos cinco classes: Vegetação, Infraestrutura, Pastagem degradada, Pastagem e Corpos d'água. Os resultados obtidos revelaram uma excelente concordância com índice *kappa* entre 0,861 e 0,983, e porcentagens mínimas para erros de omissão e inclusão nas classificações da cobertura terrestre nos projetos de assentamentos analisados. Esses resultados demonstram que a combinação de técnicas de aprendizado de máquina com imagens de satélite resulta em classificações de uso e cobertura do solo adequadas ao Plano Nacional de Reforma Agrária. Desse modo, a abordagem de sensoriamento remoto configura-se como uma ferramenta eficaz e de custo-benefício atrativo, para o poder público, tanto no ordenamento fundiário quanto na execução da reforma agrária nos projetos de assentamentos no território brasileiro.

Palavras-chave: uso e cobertura do solo; aprendizado de máquina; assentamentos.

Abstract

Knowledge of land use and land cover assists in decision-making in the land regularization process and in the development of the National Agrarian Reform Plan executed by INCRA, through the Regional Superintendencies in each Brazilian state. In this study, we investigate the application of machine learning techniques using the Support Vector Machine algorithm, combined with PlanetScope satellite images from October 2022, for supervised classification of land use and land cover in 15 settlement projects in the state of Acre. For sample training, we defined five classes: Vegetation, Infrastructure, Degraded Pasture, Pasture, and Water Bodies. The results obtained revealed excellent agreement with kappa indices ranging from 0.861 to 0.983, and minimal percentages for omission and inclusion errors in land cover classifications in the analyzed settlement projects. These results demonstrate that the combination of machine learning techniques with satellite imagery yields land use and land cover classifications suitable for the National Agrarian Reform Plan. Thus, remote sensing approaches emerge as an effective and cost-beneficial tool for the government, both in land management and in the execution of agrarian reform in settlement projects across Brazilian territory.

Keywords: land use and cover; machine learning; Settlements.





INTRODUÇÃO

O Plano Nacional de Reforma Agrária (PNRA) consiste em atingir suas metas e objetivos a partir do cumprimento dos preceitos constitucionais e da aplicação do Estatuto da Terra. Os objetivos do PNRA visam promover a distribuição da terra através da eliminação gradativa do latifúndio e minifúndio, contribuir para o aumento da oferta de alimentos, fomentar a criação de novos empregos no setor rural; criar medidas para diminuir o êxodo rural, contribuir para aumentar os benefícios sociais proporcionados pelo desenvolvimento do setor rural e promover a paz social no meio rural. Tais premissas têm como fim conceder o crescimento da produção e da produtividade em consonância aos princípios de justiça social e o direito de cidadania do trabalhador rural.

Desse modo, as diretrizes substanciais empregadas nesse plano correspondem a garantia da função social da propriedade; as empresas rurais não serão desapropriadas; a reforma agrária não atingirá as terras que estiverem produzindo; os pequenos e médios agricultores não serão atingidos pelas desapropriações; essas serão pagas mediante indenização e as terras desapropriadas serão transferidas como determina a lei. A esse respeito, o direito à propriedade é garantido pela constituição (art. 153, § 22), logo, a finalidade do uso da terra está atrelada ao bem-estar coletivo. Assim, a reforma agrária irá atingir apenas as propriedades que não exploram de maneira econômica e racional a propriedade, deixando de lado o cumprimento da função social, conforme prevê o Estatuto da Terra (Lei nº 4.504, de 30 de novembro de 1964) (Decreto nº 91.766, de 10 de outubro de 1985).

O Instituto Nacional de Colonização e Reforma Agrária (Incrá) é a autarquia federal responsável pela execução do PNRA, incumbidos da governança das terras em território nacional por meio do ordenamento da estrutura fundiária e a execução da reforma agrária. Essa tarefa envolve desde a identificação dos beneficiários até a regularização dos títulos de posse, além da promoção da prosperidade econômica das comunidades rurais nas glebas e assentamentos (Decreto nº 1.110 de 1970). Esse mecanismo é crucial para o desenvolvimento territorial, pois, se configura em uma medida que garante o acesso e direito à terra de modo a garantir a função social da propriedade rural, sendo importante para o combate à desigualdade socioeconômica.

As ações de reforma agrária são executadas de forma descentralizada pelas Superintendências Regionais (SRs) do Incra que estão presentes nos 26 Estados da Federação e no Distrito Federal (Plano de Trabalho – Incra, 2021). O assentamento de reforma agrária corresponde a um conjunto de unidades agrícolas, que são concedidas às famílias de agricultores ou trabalhadores rurais em vulnerabilidade social e econômica que não possuem condições para adquirir um imóvel (BERGAMASCO; NORDER, 1996, p. 07). Além do assentamento ser um termo utilizado para identificar áreas de terras oriundas dos processos de reforma agrária, ele também se refere a um “agregado heterogêneo de grupos sociais constituídos por famílias de trabalhadores rurais” (CARVALHO, 1998, p. 04).

As modalidades de projetos criadas pelo Incra são, o Projeto de Assentamento Federal (PA), Projeto de Assentamento Agroextrativista (PAE) e o Projeto de Desenvolvimento Sustentável (PDS). Em comum, todos os projetos possuem a aquisição da terra, seleção dos beneficiários e a criação do projeto, além do aporte de recursos de instalação e produção, a garantia de infraestrutura básica e do título de propriedade, sendo esses direitos assegurados através do Incra (INCRA, 2021).



O PAE é destinado aos beneficiários de comunidades de origem extrativista que desempenham atividades ambientalmente diferenciadas, o PDS são designados para as populações tradicionais (ribeirinhos, comunidades extrativistas etc.) que visa também o desenvolvimento de atividades ambientalmente diferenciadas, possuem o aporte de recursos Pronaf A e C e a titulação da propriedade é coletiva. Já o Projeto de Assentamento Florestal (PAF) é uma modalidade relacionada às atividades de manejo de recursos florestais que visa uma produção comunitária e sustentável. Essa área é administrada pelos assentados sob o Termo de Concessão de Uso (TCU) através de uma associação ou cooperativa, e é de responsabilidade do Incra em conjunto com Ibama, órgãos estaduais e a sociedade civil organizada.

Por último, o Projeto Descentralizado de Assentamento Sustentável (PDAS) beneficia os produtores rurais sem-terra no entorno da área urbana que desenvolvem atividades ecologicamente sustentáveis através da agricultura familiar. A área pode ser adquirida pelo Incra ou doada e cedida pelos governos estaduais ou municipais e as condições para o acesso às políticas públicas pelos assentados são garantidos por um Acordo de Cooperação firmado pelo Incra e o órgão responsável pela política agrária do local (INCRA, 2020; LOUZADA, 2011).

O plano da Reforma Agrária no Brasil totaliza 9.431 projetos de assentamentos (PAs) criados ou reconhecidos pelo INCRA em 2.100 municípios, com 969 mil famílias assentadas em 87,7 milhões de hectares. A região Norte contribui com 23,01% dos projetos de assentamentos, 44,11% das famílias assentadas com 75,47% da área destinada à reforma agrária do país. A Amazônia Legal lidera o ranking dos índices de irregularidades com 66% e desses apenas 37% foram tratados (Plano de Trabalho – Incra, 2021). Para a finalidade deste artigo a área de estudo abrange a região da Amazônia Legal, com ênfase na Superintendência Regional (SR) do estado do Acre, que possui 155 projetos de assentamentos, 30.953 famílias assentadas e 5.479.764,727 hectares de área (INCRA, 2022).

O conhecimento do uso e cobertura do solo contribui para escolhas assertivas por parte dos agentes do poder público referente a designação da atividade a exercer e os recursos e práticas necessárias para o seu pleno desenvolvimento. Neste contexto, é imprescindível o conhecimento acerca das particularidades, potencialidades e limitações dos elementos ambientais e socioeconômicos para o estabelecimento de um assentamento rural (CHAVES; LIMA, 2021). Nessa perspectiva, considerando a extensão do território nacional, o uso de geotecnologias para o monitoramento do uso e cobertura do solo permite diagnósticos prévios que auxiliam no rastreamento de áreas sensíveis e orientam a execução de possíveis intervenções *in loco*. Tais intervenções, quando ocorrem, podem ser previamente planejadas, o que exclui a locomoção para a área sem o conhecimento de causa, o que configura uma eficiente ferramenta de gestão por parte dos órgãos competentes pela criação e distribuição dos assentamentos rurais em território nacional.

Os mapeamentos da cobertura terrestre podem ser obtidos com o emprego do sensoriamento remoto combinado com técnicas de aprendizado de máquina e imagens de satélites com alta resolução espacial, de forma a classificar os objetos através dos elementos de reconhecimento, como: cor, tonalidade, forma, contexto, textura, altura, tamanho etc. (SHANAHAN et al. 2001). Monard & Baranauskas (2003) definem aprendizado de máquina como um sistema capaz de adquirir conhecimento de forma automática, tomando decisões baseadas no conhecimento obtido em resoluções bem-sucedidas de problemas anteriores (OLIVEIRA, et. al, 2023). A classificação digital de imagem pode ser não supervisionada,



sendo baseada em análises estatísticas com o emprego de amostras a posteriori, e supervisionada quando se tem um conhecimento prévio das classes na imagem da área a ser analisada e essas são definidas a priori (LIU, 2006). Desse modo, a classificação de imagens apresenta resultados satisfatórios quando aplicada à identificação do uso e cobertura do solo, sendo um método confiável para a elaboração de mapas temáticos (MULDER et al. 2011; MOREIRA et. al. 2014; BARROS, 2018; BLASIUŠ et. el. 2022).

As imagens de satélites multiespectral proporcionam uma grande fonte de informações para a análise das mudanças espaciais e temporais e podem ser aplicadas na classificação da cobertura terrestre (PATKI; KELKAR, 2013). Para a finalidade deste estudo o uso de imagens Planet se apresenta como a melhor opção dentre as disponíveis (Planet, 2023). Tais imagens são adquiridas pela constelação PlanetScope, que consiste em vários lançamentos de satélites Dove, desde 2015 e possuem 10 cm por 10 cm por 30 cm (CubeSat3), indicando seu tamanho compacto padronizado (CubeSat, 2012; CGEE, 2018). Conforme estudos realizados por Pinheiro, et. al (2019) para a aplicação do Cadastro Ambiental Rural (CAR) o sensoriamento remoto combinado com imagens Planet resultou em uma classificação adequada quando aplicada ao uso e ocupação do solo o que mostra a efetividade desse método. Para Oliveira, et. al (2023) o uso de sensoriamento remoto e aprendizado de máquina aplicado à investigação do mapeamento hídrico também mostrou resultados confiáveis para classificação e análise terrestre.

Para alcançar o mapeamento e avaliação do uso e cobertura do solo, são empregadas ferramentas computacionais, como aprendizado de máquina e geotecnologias. Essas ferramentas são aplicadas em conjunto para processar dados de sensoriamento remoto, produzindo resultados que auxiliam no planejamento de ações de manejo. Isso não só contribui para a solução de problemas, mas também promove melhorias na qualidade de vida e nos recursos naturais.

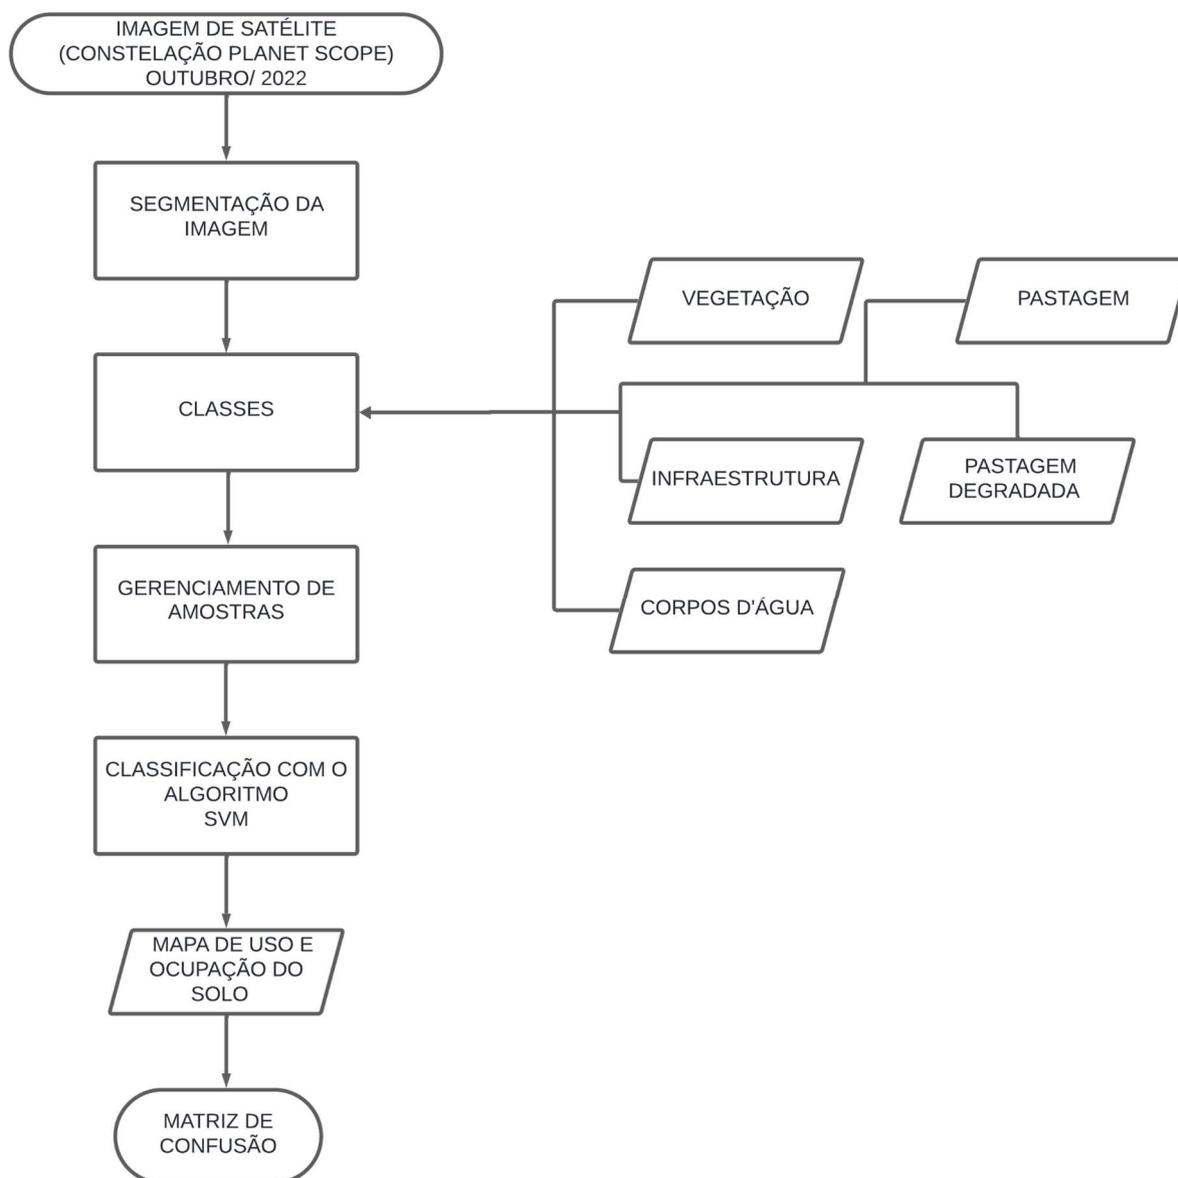
Nesse estudo, iremos aplicar a técnica de aprendizado de máquina combinado ao algoritmo Suporte de Vetor de Máquina (SVM) e imagens de satélite PlanetScope na classificação supervisionada do uso e cobertura do solo em projetos de assentamento no estado do Acre. Para verificar o desempenho do algoritmo, será aplicado o índice *kappa*, erros de omissão e inclusão. Espera-se obter resultados que assegurem a eficácia do método na investigação da cobertura terrestre no âmbito do ordenamento fundiário para execução da reforma agrária no Brasil.

METODOLOGIA

Para analisar a aplicabilidade da técnica de aprendizado de máquina combinado com algoritmo SVM e imagens de satélite na investigação do uso e cobertura do solo em projetos de assentamento de reforma agrária, foram realizadas as seguintes etapas: (i) obtenção das imagens de satélite; (ii) processamento dos dados no software ArcGIS; (iii) análise dos resultados, conforme apresentado na Figura (1).



Figura 1 – Fluxograma da execução da metodologia.



Fonte: Elaborado pelo autor, 2023.

Localização e caracterização da área de estudo

A área de estudo deste trabalho corresponde aos projetos de assentamentos: PAF Havaí, PAF Recanto, PDS Francisco Pimentel, PDS Minas, PA Treze de Maio, PA São Pedro, PA Pedro Firmino, PA Pavão, PA Narciso Assunção, PA Iucatan, PA Arco Íris, PA Alberto Santiago, PA Amônia, PA Paraná dos Mouras, PA Nova Cintra. Os assentamentos pertencem à Microrregião Cruzeiro do Sul, localizada no estado do Acre, Brasil. A microrregião Cruzeiro do Sul possui 7.924,943 km² de extensão e engloba os municípios: Cruzeiro do Sul, Mâncio Lima, Marechal Thaumaturgo, Porto Walter e Rodrigues Alves (Acre.gov), conforme representando na Figura 2.

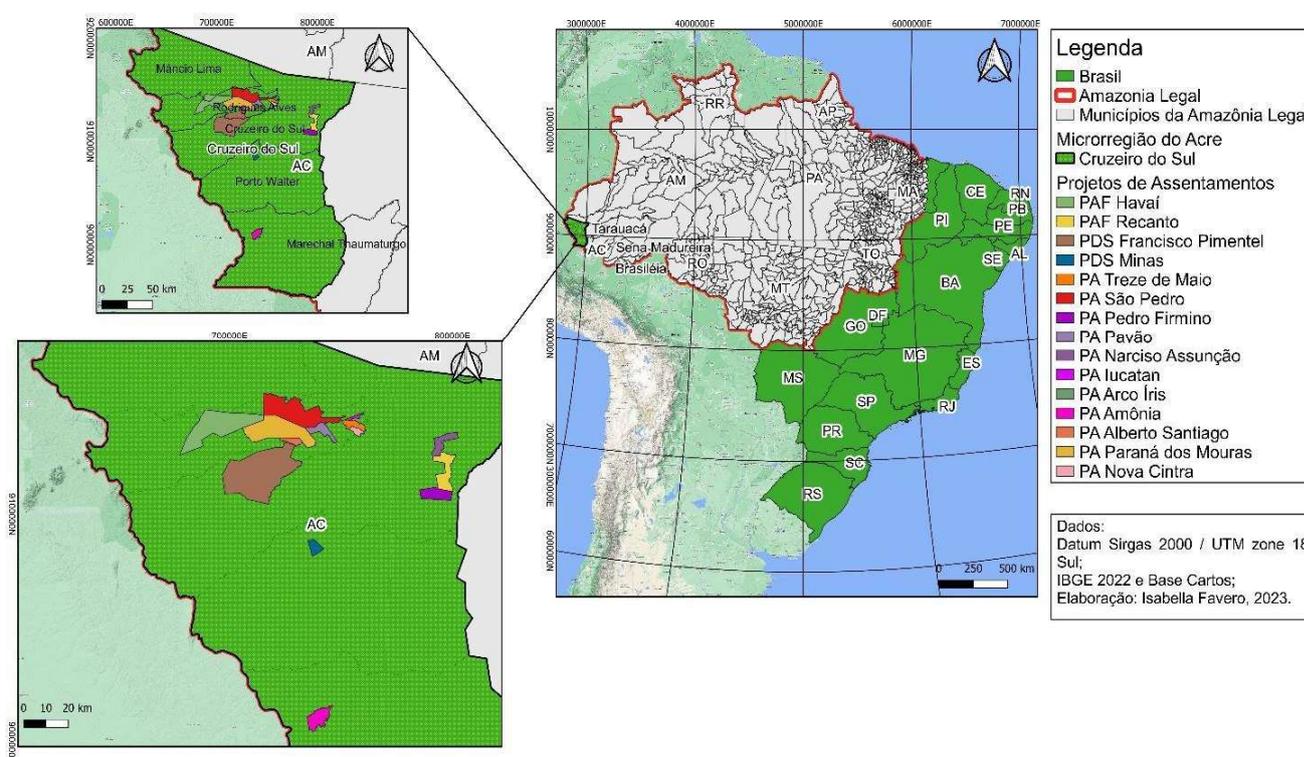
O Acre, em extensão territorial, possui 164.221,36 km², que corresponde a 4,26% da Região Norte e a 1,92% do território nacional. O Estado está situado num planalto com altitude



média de 200 m, localizado no sudoeste da Região Norte, entre as latitudes de 7°06'56 S e longitude 73° 48' 05"O, latitude de 11° 08' 41"S e longitude 68° 42' 59"O. Conforme Köppen e Geiger, o Acre pertence ao grupo A – tropical, e apresenta um clima equatorial (Af) com temperatura média de 25.1 °C e pluviosidade média significativa ao longo do ano de 2.169 mm. Os limites do Estado são formados por fronteiras internacionais com Peru (O) e Bolívia (S) e por divisas estaduais com os estados do Amazonas (N) e Rondônia (L). As cidades mais populosas são: Rio Branco, Cruzeiro do Sul, Feijó, Tarauacá e Sena Madureira.

Figura 2 – Mapa de Localização da área de estudo.

Localização dos Projetos de Assentamentos - Microrregião Cruzeiro do Sul / Acre



Fonte: Elaborado pelo autor, 2023.

Na Tabela 1, a relação dos projetos de assentamentos analisados corresponde, em sua totalidade, a 176.195,138 hectares e 1.894 famílias assentadas. Os referidos dados foram extraídos do banco de informação do MAPA (Ministério da Agricultura, Pecuária e Abastecimento), disponibilizado no site institucional do Incra, referente ao relatório de dezembro de 2022, que abrange os projetos de reforma agrária com período de criação entre 1900 e 2022 (INCRA, 2022). Nessa perspectiva, observa-se um número expressivo de famílias assentadas nos 15 (quinze) projetos de assentamentos na Microrregião Cruzeiro do Sul, no Acre. Essas famílias obtêm desse território, os recursos para suprir as necessidades básicas em relação aos aspectos habitacional e financeiro.

Tabela 1 – Projetos de Assentamentos.



Projeto de Assentamentos	Município	Área (ha)	Nº de famílias assentadas
PAF Havaí	Mâncio Lima	29.686,719	113
PAF Recanto	Cruzeiro do Sul	9.030,630	86
PDS Francisco Pimentel	Rodrigues Alves	54.393,386	165
PDS Minas	Porto Walter	2.895,668	85
PA Treze de Maio	Rodrigues Alves	2.836,511	143
PA São Pedro	Rodrigues Alves	25.437,971	323
PA Pedro Firmino	Cruzeiro do Sul	6.401,848	78
PA Pavão	Rodrigues Alves	4.230,954	55
PA Narciso Assunção	Cruzeiro do Sul	4.950,497	81
PA Iucatan	Rodrigues Alves	849,488	41
PA Arco Íris	Rodrigues Alves	1.404,146	68
PA Amônia	Marechal Thaumaturgo	6.621,560	158
PA Alberto Santiago	Rodrigues Alves	2.169,956	51
PA Paraná dos Mouras	Rodrigues Alves	23.821,395	388
PA Nova Cintra	Rodrigues Alves	1.464,404	59
Total		176.195,138	1.894

Fonte: MAPA/SIPRA/SDM.

Organizado pelo autor, 2023.

PA – Projeto de Assentamento Federal; PAF – Projeto de Assentamento Floresta; PDS – Projeto de Desenvolvimento Sustentável.

Imagens Planet

Para este trabalho, foram utilizados 15 (quinze) ortomosaicos, obtidos da constelação PlanetScope, os quais possuem uma distância amostral do solo de 4.77 m, expressando quantos metros da superfície terrestre cada pixel na imagem representa. Isso significa que a imagem pode mostrar detalhes finos na superfície terrestre com bastante clareza. As bandas espectrais correspondem ao espectro Azul (455-515 nm), Verde (500-590 nm), Vermelho (590-670 nm) e Infra-Vermelho Próximo (780-860 nm). O tempo de revisita é diário na órbita síncrona ao Sol, com uma capacidade de 200 milhões de km²/dia (Planet Team, 2023). As imagens são disponibilizadas com nível de processamento que inclui ortorretificação e valores de refletância de superfície, o que elimina a necessidade de calibração radiométrica e atmosférica. Para a classificação do uso e cobertura do solo, foram utilizadas imagens do tipo *normalized*, de outubro de 2022, obtidos gratuitamente pelo Programa Internacional de Dados de Satélite da Iniciativa Internacional de Clima e Florestas da Noruega (NICFI - <https://www.planet.com/nicfi/>).

Segmentação

A segmentação de imagem usada neste trabalho é baseada na abordagem Mean Shift, técnica que usa o valor médio de cada pixel para determinar quais devem ser incluídos em cada segmento. A segmentação da imagem depende de três parâmetros: detalhe espectral, detalhe espacial e tamanho mínimo do segmento em pixels. O detalhe espectral define o nível de importância dado às diferenças espectrais de recursos em suas imagens, enquanto o detalhe espacial diz respeito à proximidade entre os elementos. Em ambos os parâmetros, um número



pequeno corresponde a um resultado com mais suavização e menos detalhes, por outro lado, um número maior resulta em detalhes mais precisos dos objetos. Por último, o tamanho mínimo do segmento está diretamente relacionado à sua unidade de mapeamento, o que implica na fusão de segmentos menores com seus vizinhos mais adequados. (COMANICIU; MEER, 2002).

Após diversos testes, adotou-se os valores de detalhe espectral equivalente a 20, detalhe espacial de 19 e tamanho mínimo do segmento em pixels de 20. O processo de segmentação extrai informações das imagens pela agregação de objetos em classes de atributos, gerando resultados visualmente mais consistentes e de fácil conversão em sistemas de informações geográficas, se comparado a classificação em pixels (ESPÍNDOLA, 2006). Na figura 3 está disposto em (a) a imagem de satélite e em (b) a mesma imagem, segmentada conforme os parâmetros acima, que foram usados como base para a classificação do uso e cobertura do solo nos projetos de assentamentos.

Figura 3 – Imagem segmentada.



a) Imagem de satélite



b) Imagem de satélite segmentada

Fonte: Elaborado pelo autor, 2023.

Técnica de Aprendizado de Máquina

O aprendizado de máquina está inserido no contexto da Inteligência Artificial e permite a aquisição de conhecimento de forma automática, por meio de algoritmos que aprendem interativamente a partir dos dados recebidos. Essa técnica combinada ao sensoriamento remoto produz resultados satisfatórios devido à sua concordância e acurácia, especialmente quando adotados na classificação de imagens de satélite. O algoritmo Suporte de Vetor de Máquina (SVM) é um dos mais eficientes usados no aprendizado de máquina. Sua abordagem consiste na separação máxima das classes através da construção de um hiperplano ideal, também denominado de superfície de decisão. Estudos realizados por Patki e Kelker (2013); Moreira, Fernandes e Nery (2014); Tangthaikwan (2017); Duarte (2022) obtiveram resultados entre forte a excelente concordância em relação à análise do Índice Kappa ao empregar o algoritmo SVM para a classificação da cobertura terrestre.

Gerenciador de Amostras de Treinamento



Esta etapa consistiu em treinar o modelo ao empregar a estrutura de imagens, que se refere à utilização de dados de imagem como entrada para o treinamento do algoritmo, esses dados são essencialmente matrizes de pixels com valores de intensidade correspondentes às cores. Para isto, foram vetorizadas 5 classes e 50 amostras de cada uma foram anotadas, nos 15 (quinze) assentamentos analisados, denominadas: vegetação, infraestrutura (estrada, área edificada), pastagem degradada (solo exposto, solo queimado), pastagem e corpos d'água. Na figura (5) é apresentada a matriz de confusão das classes correspondente a cada projeto de assentamento.

Processamento dos Dados

Foram obtidas 15 (quinze) imagens de satélite através do *database* da Planet, referentes ao mês de outubro de 2022, na qual os *rasters* foram recortados conforme a camada *shapefile* dos limites de cada projeto de assentamento. Consequente, os *rasters* foram segmentados, as amostras foram coletadas conforme as classes definidas e as imagens foram classificadas usando o algoritmo SVM. Por fim, foi obtida a matriz de confusão correspondente a cada classificação. O processamento dos dados foi realizado no software ArcGis Pro (3.0.0).

Avaliação de acurácia

Para verificar o desempenho do algoritmo SVM para classificação do uso e cobertura do solo, foi utilizado o índice *kappa*, que permite uma avaliação da precisão de cada classe por meio da matriz de confusão, sendo capaz de fornecer uma base para identificar a precisão da classificação e caracterizar os erros, o que colabora para o refinamento e assertividade das imagens classificadas (FIGUEIREDO; VIEIRA, 2007). O desempenho do algoritmo também foi analisado ao verificar os erros de omissão e de inclusão, sendo o primeiro correspondente aos pixels erroneamente atribuídos à classe de interesse e o segundo referente aos pixels que pertencem a área de interesse, mas o classificador atribui a outra classe (NASCIMENTO et al., 2009).

O índice *kappa* pode ser calculado através da equação abaixo, e sua concordância está apresentada na tabela 2:

$$K = \frac{N \sum_{i=1}^r \blacksquare X_{ii} - \sum_{i=1}^r \blacksquare (X_{i+} * X_{+i})}{N^2 - \sum_{i=1}^r \blacksquare (X_{i+} * X_{+i})}$$



Em que:

N = número total de amostras;

$\sum_{i=1}^r X_{ii}$ = soma do número das amostras corretas nas linhas e colunas;

X_{i+} = soma linear; X_{+i} soma colinear.

Tabela 2 – Valores de Índice Kappa

Índice Kappa	Concordância
<0	Sem concordância
0.00 - 0.19	Pobre
0.20 – 0.39	Fraca
0.40 – 0.59	Moderada
0.60 – 0.79	Forte
0.80 a 1.00	Excelente

Fonte: Landis e Koch (1977).

O Erro de Omissão pode ser calculado através da equação:

$$Eo = \frac{X_{i+} - X_{ii}}{X_{i+}}$$

Em que:

Eo = erros de omissão;

X_{i+} = marginal da linha;

X_{ii} = diagonal daquela linha.

O Erro de Inclusão pode ser calculado através da equação:

$$Ei = \frac{X_{+i} - X_{ii}}{X_{+i}}$$

Em que:

Ei = erros de inclusão;

X_{+i} = marginal da coluna;

X_{ii} = diagonal daquela coluna.

RESULTADOS

Os resultados obtidos com a aplicação do algoritmo SVM na classificação supervisionada no mapeamento do uso e cobertura do solo em projetos de assentamentos são apresentados em mapas temáticos expostos na figura (4).

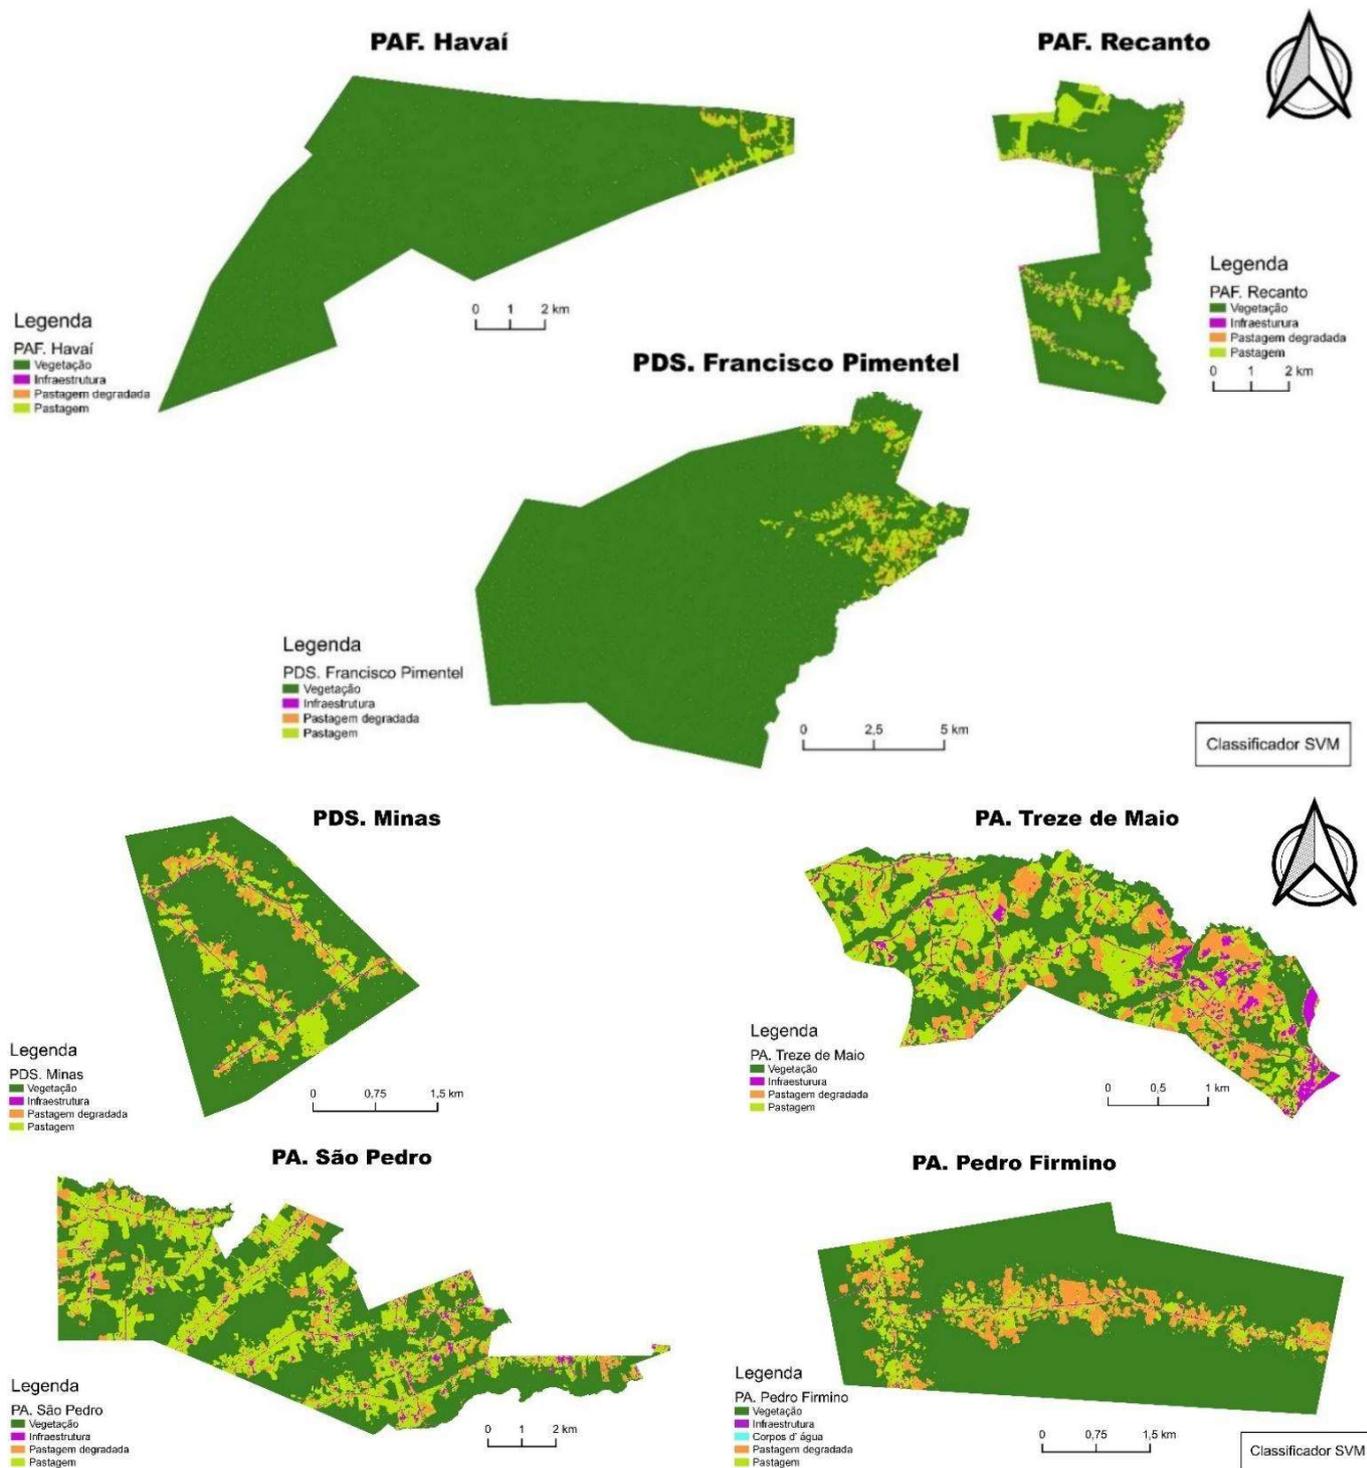
A área de estudo classificada pelo algoritmo apresentou coerência com as características da região e mostrou bons resultados visuais na caracterização do comportamento da cobertura da terra nos assentamentos.

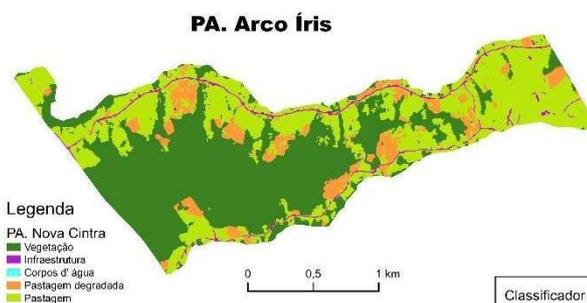
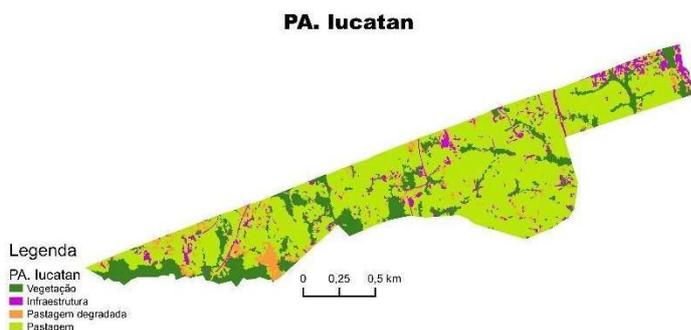
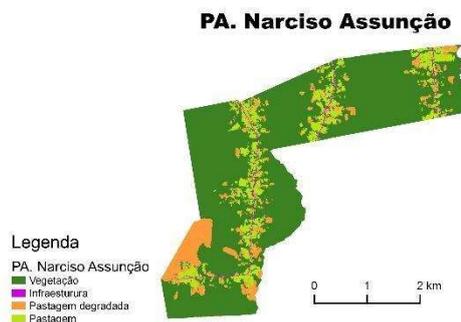
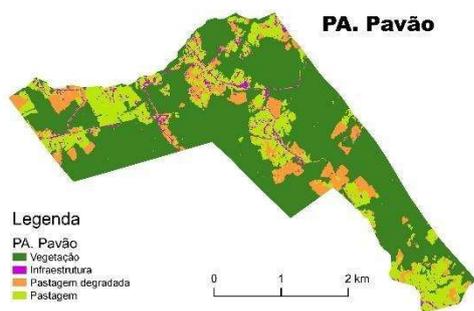
Mapas Classificados



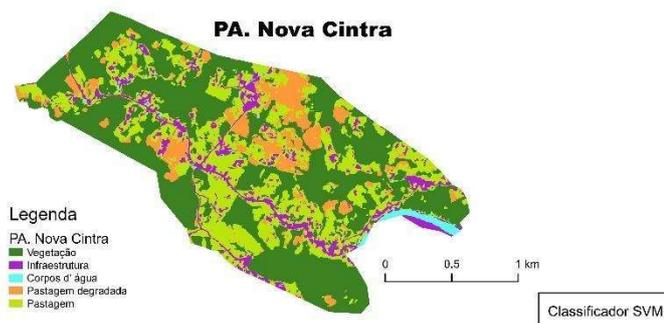
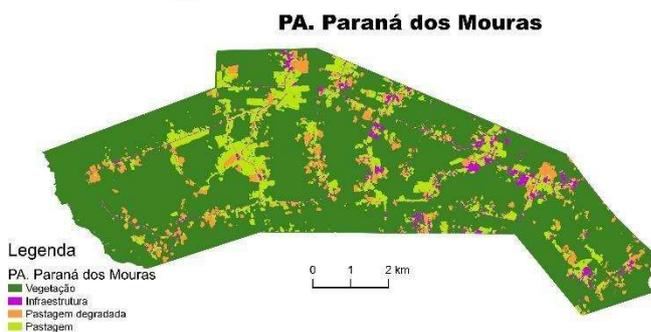
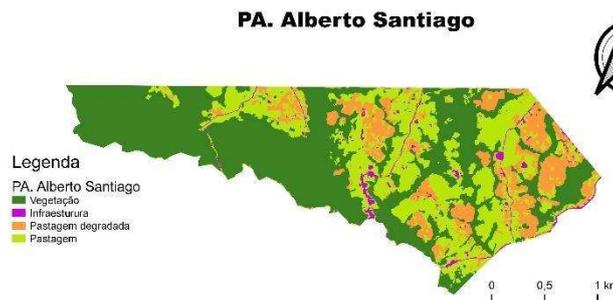
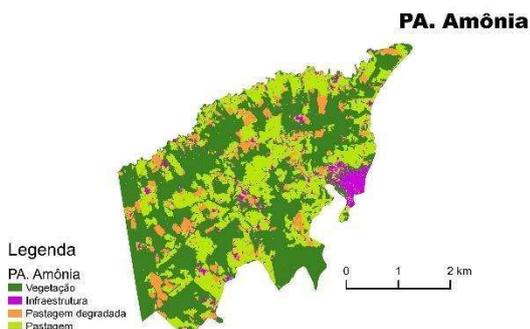
Os mapas temáticos dos 15 projetos de assentamentos no Acre, resultado da classificação do uso e cobertura do solo, são apresentados abaixo:

Figura 4 – Classificações.





Classificador SVM



Classificador SVM

Fonte: Elaborado pelo autor, 2023.

Na análise do Índice Kappa, o classificador SVM obteve concordância excelente, superior a 0,86 nas quinze (15) classificações do uso e ocupação do solo, conforme apresentado na Tabela 3.

Tabela 3 – Índice Kappa.

Projeto de Assentamentos	Índice Kappa	Concordância
--------------------------	--------------	--------------



PAF Havaí	0,944	Excelente
PAF Recanto	0,862	
PDS Francisco Pimentel	0,861	
PDS Minas	0,964	
PA Treze de Maio	0,940	
PA São Pedro	0,973	
PA Pedro Firmino	0,962	
PA Pavão	0,980	
PA Narciso Assunção	0,953	
PA Iucatan	0,955	
PA Arco Íris	0,983	
PA Amônia	0,911	
PA Alberto Santiago	0,951	
PA Paraná dos Mouras	0,863	
PA Nova Cintra	0,946	

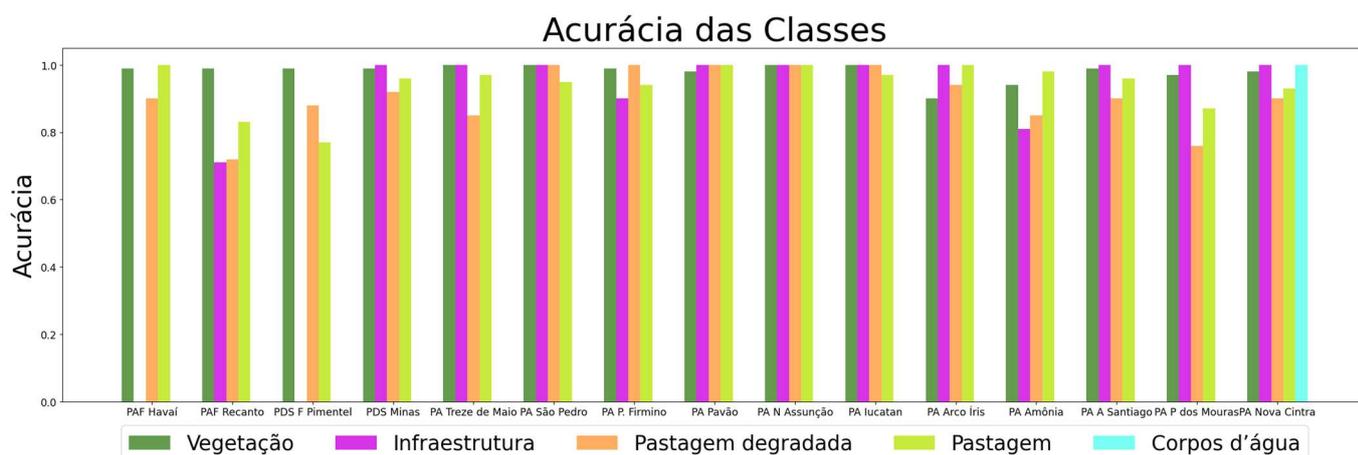
Fonte: Elaborado pelo autor, 2023.

O gráfico disposto na figura (5) apresentou os valores de acurácia das classes respectivas a cada assentamento. No PAF Havaí e PDS Francisco Pimentel o classificador não identificou a classe infraestrutura. Já no PAF Recanto, a mesma classe apresentou o menor valor de acurácia (0,714) ao se comparar com os outros assentamentos.

Dentre as classes mapeadas, a que se refere aos corpos d'água foi identificada apenas na PA Nova Cintra. Vale destacar que ao analisar as imagens de satélites, a presença de cursos hídricos foi reconhecida nas proximidades dos limites dos assentamentos e não em seu interior. No caso do PA supracitado, foi constatada, através da classificação de uso e cobertura do solo apresentada na figura (5), a presença dessa classe em sua extremidade. O PAF Recanto apresentou valores de acurácia menores para as classes infraestrutura e pastagem degradada se comparadas às demais classificações. Os demais Índices (erros de omissão e inclusão) também apresentaram os menores valores para esse assentamento.

A classe pastagem degradada corresponde às cicatrizes de queimadas e solo exposto, e foi identificada nos 15 (quinze) assentamentos classificados nesse estudo. As áreas de interesse estão inseridas dentro da Amazônia Legal, onde a incidência de focos de queimada é recorrente. Segundo o banco de dados de monitoramento de queimadas do INPE, em 2022, tiveram cerca de 1184 focos ativos de queimada. Com esse cenário, e ao fato dos assentamentos possuírem caráter de moradia e de fonte de renda para a população assentada dentre estas comunidades tradicionais, a ocorrência de focos de queimadas como as identificadas nas imagens de satélite e analisadas na classificação supervisionada, desperta um alerta em relação aos seus impactos e respectivos danos à qualidade de vida e a produtividade dentro dos assentamentos.

Figura 5 – Acurácia das Classes.



Fonte: Elaborado pelo autor, 2023.

Pode-se verificar, por meio da matriz de erros na Tabela 4, que dentre o desempenho do algoritmo SVM no mapeamento de cada classe da área de estudo, a classe infraestrutura apresentou o maior erro de omissão, na qual 70% dos pixels foram erroneamente atribuídos a essa classe. Já para a classe vegetação, 66% dos pixels que deveriam pertencer a esta classe, foram atribuídos a outra classe. Os maiores erros de omissão e inclusão entre as classificações realizadas foram encontrados no PA dos Mouras e PAF Recanto, respectivamente. São resultados significativos e que não ocorrem nas outras áreas analisadas neste estudo. Uma das hipóteses para este fato pode ser atribuída à complexidade da paisagem em termos de variabilidade espectral, o que torna mais difícil para o algoritmo SVM fazer distinções claras entre as classes. A outra seria por haver uma mistura espectral significativa, onde os pixels contêm informações espectrais de mais de uma classe. Isto pode ter influenciado na segmentação e consequentemente na assertividade da classificação.

Ao comparar os trabalhos que analisam o desempenho do algoritmo SVM no mapeamento da composição do espaço terrestre, (MULDER et al. 2011; MOREIRA et al., 2014; NASCIMENTO et al., 2009; BARROS, 2018; BLASIUS et. el. 2022), os resultados apresentados nesse estudo também obtiveram índices *kappa* com concordância entre forte a excelente e valores consistentes nas análises dos erros de inclusão e omissão.

De modo geral, o algoritmo demonstrou a capacidade em reconhecer corretamente as instâncias de cada classe. Os erros de omissão e inclusão foram mínimos e os índices *kappa* obtidos na tabela (3) corroboraram esses resultados, o que evidenciou o alto grau de concordância entre as classificações. A acurácia das classes apresentada na figura (5) também revelou o desempenho consistente e preciso para identificar as diferentes classes.

Tabela 4 - Matriz de Erros do classificador SVM.



Classes	Matriz de Erro do Classificador SVM									
	Vegetação		Infraestrutura		Pastagem Degradada		Pastagem		Corpos d'água	
	Eo (%)	Io (%)	Eo (%)	Io (%)	Eo (%)	Io (%)	Eo (%)	Io (%)	Eo (%)	Io (%)
PAF Havaí	-	0,55%	-	-	10%	10%	10%	0	-	-
PAF Recanto	7,14%	66%	50%	28,57%	20%	27,27%	7,14%	16,12%	-	-
PDS F Pimentel	0%	0,55%	-	-	20%	11,11%	30%	22,22%	-	-
PDS Minas	0,67%	0,67%	0%	0%	7,69%	7,69%	3,57%	64,93%	-	-
PA Treze de Maio	1,26%	0%	13,33%	0%	0%	17,14%	6,49%	2,70%	-	-
PA São Pedro	0%	0%	30%	0%	0%	0%	0%	4,16%	-	-
PA Pedro Firmino	0,65%	0,65%	0%	9,09%	5%	0%	5,88%	5,88%	-	-
PA Pavão	0%	1,51%	0%	0%	0%	0%	5%	0%	-	-
PA N Assunção	0%	0%	0%	0%	0%	0%	0%	0%	-	-
PA Lucatan	5,55%	0%	7,62%	0%	10%	0%	0%	2,75%	-	-
PA Arco Iris	0%	0%	0%	9,09%	0%	5,55%	2,53%	0%	-	-
PA Amônia	2,15%	5,20%	10%	18,18%	10%	14,28%	7,29%	1,38%	-	-
PA A Santiago	0%	0%	0%	9,09%	0%	5,55%	2,53%	0%	-	-
PA dos Mouras	0%	2,72%	70%	0%	7,14%	23,52%	12,12%	12,12%	-	-
PA Nova Cintra	0%	1,02%	20%	0%	4,76%	9,09%	1,75%	6,66%	20%	0%

Fonte: Elaborado pelo autor, 2023.

PA – Projeto de Assentamento Federal; PAF – Projeto de Assentamento Floresta; PDS – Projeto de Desenvolvimento Sustentável.

Eo – Erro de Omissão; Io – Erro de Inclusão

CONSIDERAÇÕES FINAIS

O presente estudo teve por objetivo avaliar a eficácia da aplicação da técnica de aprendizado de máquina ao combinar o algoritmo Suporte de Vetor de Máquina (SVM) com imagens de satélite PlanetScope em 15 (quinze) projetos de assentamentos de reforma agrária localizados na microrregião Cruzeiro do Sul, pertencente ao estado do Acre/Brasil).

Constatou-se que o método aplicado configura uma ferramenta eficaz para classificação e análise de uso e cobertura do solo em assentamentos, sendo um instrumento de custo-benefício atrativo ao poder público no contexto do ordenamento fundiário, bem como na execução da reforma agrária nos projetos de assentamentos no Brasil.

Cabe ressaltar a importância do monitoramento da cobertura terrestre por meio de sensoriamento remoto, pois as análises realizadas por meio dessa ferramenta reduzem o investimento financeiro e oferecem acesso a um amplo panorama do local de interesse.

Destaca-se também a recomendação do relatório de avaliação realizado pela Controladoria-Geral da União para a necessidade em complementar as análises de sensoriamento remoto com vistorias presenciais, tendo em vista a carência de soluções tecnológicas disponíveis no Incra para atender a vasta demanda, e com isso, assegurar os requisitos cobrados por lei (ocupação, exploração, cultura efetiva) no processo de regularização fundiária no território brasileiro (CGU – Auditoria, 2019).

Por fim, sugere-se para estudos futuros, pesquisas no âmbito das metodologias aplicadas pelo Incra e o aprimoramento de técnicas de sensoriamento remoto que possam ser empregadas na execução e aperfeiçoamento da reforma agrária no Brasil.

AGRADECIMENTOS



O presente trabalho foi realizado como apoio da Fundação de Apoio à Pesquisa, ao Ensino e à Cultura - Brasil (FAPEC); Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil (CNPq) e Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul (FUNDECT).

REFERÊNCIAS

ACRE. Disponível em: <http://acre.gov.br/acre/>. Acesso em: 5 abr. 2023.

BARROS, Kamila Lemos Costa; SILVA, Eliane Maria Ribeiro da; MENDONÇA, Bruno Araújo Furtado de; PEREIRA, Marcos Gervasio; FRANCELINO, Márcio Rocha. Análise Temporal Da Cobertura E Uso Da Terra Do Assentamento Rural Fazenda Do Salto – Barra Mansa, Rj. *Geo UERJ*, [s. l.], ed. 33, 2018. DOI <https://doi.org/10.12957/geouerj.2018.31899>. Disponível em: <https://www.e-publicacoes.uerj.br/index.php/geouerj/article/view/31899>. Acesso em: 12/01/2023.

BERGAMASCO, Sonia Maria Pessoa Pereira; NORDER, Luís Antônio Cabello. O que são assentamentos rurais. São Paulo: Brasiliense, 1996.

BLASIUS, Jandir Pereira; ASSUNÇÃO, Talita Teles; SANTOS, Rodolfo Busolin Alves; ARAÚJO, Sander Faria; PEREIRA, Fernando Vasconcelos; KOPP, Katia Alcione. Análise do uso e ocupação do solo de assentamentos de reforma agrária em Uberlândia/MG. *Revista Retratos de Assentamentos*, 2022. DOI <https://doi.org/10.25059/2527-2594/retratosdeassentamentos/2022.v25i2.519>. Disponível em: <https://retratosdeassentamentos.com/index.php/retratos/article/view/526>. Acesso em: 15/03/2023.

BRASIL. Decreto nº 1.110, de 9 de julho de 1970. Cria o Instituto Nacional de Colonização e Reforma Agrária (INCRA), extingue o Instituto Brasileiro de Reforma Agrária, o Instituto Nacional de Desenvolvimento Agrário e o Grupo Executivo da Reforma Agrária e dá outras providências. 1970. Disponível em: https://www.planalto.gov.br/ccivil_03/decreto-lei/1965-1988/del1110.htm. Acesso em: 01/02/2023.

BRASIL. Decreto nº 91.766, de 10 de outubro de 1985. Decreto Nº 91.766 De 10 De Outubro De 1985. Aprova O Plano Nacional de Reforma Agrária - PNRA, e dá outras providências. 1985. Disponível em: <https://legislacao.presidencia.gov.br/atos/?tipo=DEC&numero=91766&ano=1985&ato=ee8oXQE9EMBPWT572>. Acesso em: 01/04/2023.

BRASIL. Lei nº 4.504, de 30 de setembro de 1963. Dispõe sobre o Estatuto da Terra, e dá outras providências. [S. l.], 1964. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/14504.htm. Acesso em: 01/04/2023.

CARVALHO, Horácio Martins de. Formas de associativismo vivenciadas pelos trabalhadores rurais nas áreas oficiais de reforma agrária no Brasil. Curitiba: Editora IICA/NEAD, 1998. Acesso em: 01/04/2023.

CGEE. CENTRO DE GESTÃO E ESTUDOS ESTRATÉGICOS. Resumo Executivo CubeSats. Brasília: CGEE, 2018. Disponível em: https://www.cgee.org.br/documents/10195/734063/3111_CGEE_resumoexecutivo_CubeSats_web.pdf/d25668f5-4d98-411c-b79a-e7f6f369d7bd?version=2.3. Acesso em: 01/03/2024

CHAVES, James Lima.; LIMA, José Raimundo Oliveira. Políticas públicas para segurança alimentar e nutricional: dificuldades e possibilidades observadas em relação aos agricultores do assentamento palestina, Cravolândia – Bahia. *Retratos de Assentamentos*, v. 24, n. 2, p. 39-54, 2021. Disponível em: <https://retratosdeassentamentos.com/index.php/retratos/article/view/446/403>. Acesso em: 15/03/2023.

CGU. Controladoria Geral da União. Relatório de Avaliação do Instituto Nacional de Colonização e Reforma Agrária (INCRA): Exercício 2019.

COMANICIU, Dorin; MEER, Peter. Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. v. 24, p. 603 - 619, 2002. DOI 10.1109/34.1000236. Disponível em: <https://ieeexplore.ieee.org/document/1000236>. Acesso em: 05/04/2023.

CUBESAT. California State Polytechnic University. CubeSat Design Specification Rev. 12 The CubeSat Program, Cal Poly SLO CubeSat Design Specification (CDS) Document Classification X Public Domain ITAR Controlled Internal Only. 2012. Disponível em: http://www.cubesat.org/images/developers/cds_rev12.pdf. Acesso em: 01/03/2024.



DUARTE, Priscila Gabriela Silva. Métodos de Machine Learning Aplicados à Classificação do Uso e Ocupação do Solo Na Microbacia Do Lago Igapó Na Cidade De Londrina/Pr. 2022. 77 p. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Engenharia Ambiental, Universidade Tecnológica Federal do Paraná (UTFPR), Londrina, 2022. Acesso em: 01/03/2023.

ESPINDOLA, M.G. Ajuste de parâmetro em algoritmos de segmentação de imagens por crescimento de regiões. Dissertação – Instituto Nacional de Pesquisas Espaciais (INPE), 2006. Disponível em: http://www.dpi.inpe.br/gilberto/teses/dissertacao_giovana.pdf.

ESRI. Environmental Systems Research Institute. ArcGIS Pro for Desktop Advanced. Release 2.9.0. Redlands, CA, 2021. Disponível em: <<https://www.esri.com>>.

INCRA. INSTITUTO NACIONAL DE COLONIZAÇÃO E REFORMA AGRÁRIA. Reforma Agrária. Assentamentos. Brasília: INCRA, 2021. Disponível em <https://www.gov.br/incra/pt-br/assuntos/reforma-agraria/assentamentos>. Acesso em: 25/03/2023.

INCRA. INSTITUTO NACIONAL DE COLONIZAÇÃO E REFORMA AGRÁRIA. Reforma Agrária. Assentamentos. Relação de Projetos. Brasília: INCRA, 2022. Disponível em: <https://www.gov.br/incra/pt-br/assuntos/reforma-agraria/assentamentos-relacao-de-projetos>. Acesso em: 30/03/2023.

INCRA. INSTITUTO NACIONAL DE COLONIZAÇÃO E REFORMA AGRÁRIA. Plano de Trabalho - TED Nº 34/2021/SR(28)DFE-G/SR(28)DFE/INCRA-INCRA. Brasília: INCRA, 2022. Disponível em: https://www.gov.br/incra/pt-br/centrais-de-conteudos/publicacoes/editais-de-licitacoes/termo-de-execucao-descentralizada/ted_ifg_plano_trabalho_34_2021.pdf. Acesso em: 31/03/2023.

LANDIS, JR; Koch GG. The measurement of observer agreement for categorical data. *Biometrics*. 1977 Mar;33(1):159-74. PMID: 843571.

LIU, Willian Tse Horng. Aplicações de Sensoriamento Remoto. 2. ed. Campo Grande, MS: Oficina de Textos, 2007. 539 p.

LOUZADA, Rovena Vasconcellos. Modalidades de Projetos de Assentamentos Rural: Evolução e Legislação Federal. 2011. 60 p. Trabalho de Conclusão de Curso (TCC) (Bacharelado em Engenharia Florestal) - Universidade Federal Rural do Rio de Janeiro, [S. l.], 2011. Disponível em: <http://rima.im.ufrj.br:8080/jspui/handle/1235813/5444>. Acesso em: 20/03/2023.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, p. 39, 2003. Disponível em: <https://dcm.ffclrp.usp.br/~augusto/publications/2003-sistemas-inteligentes-cap4.pdf>. Acesso em: 04/03/2023.

MOREIRA, Adriana Aparecida; FERNANDES, Fernando Hiago Souza; ALMEIDA, Rodrigo Praes; NERY, César Vinícius Mendes. O Algoritmo Support Vector Machine aplicado ao Mapeamento do Uso e Ocupação do Solo. *Revista Brasileira de Geografia Física*, v. 7, ed. 2, 2014. DOI <https://doi.org/10.26848/rbgf.v7.2.p291-303>. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/view/233041>. Acesso em: 12/01/2023.

MULDER, V. L.; BRUIN, S. de; SCHAEPMAN, M. E.; MAYR, T. R. The use of remote sensing in soil and terrain mapping - A review. *Geoderma*, n. 162, p. 1-19, 2011. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0016706110003976>. Acesso em: 05/04/2023.

NASCIMENTO, R. F. F; ALCÂNTARA, E. H; KAMPEL, M; STECH, J. L; NOVO, E. M. L. M; Support Vector Machines (SVM): Avaliação da separação ótima de classes em imagens CCD-CBERS-2. *Anais XIV SBSR, Natal, Brasil, 2009*, INPE, p. 2079-2086. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/10.20.10.59/doc/2079-2086.pdf>. Acesso em: 14/05/2023.

OLIVEIRA, Lucas. OSCO, Lucas Prado. JR, José Marcato. RAMOS, Ana Paula Marques. Souza, Mauricio. Sensoriamento remoto e aprendizado de máquina aplicados no mapeamento hídrico do Sistema Cantareira. *Revista Tamoios, São Gonçalo*, v. 19, n. 1, p. 193-206, 2023. Disponível em: <https://doi.org/10.12957/tamoios.2023.63354>. Acesso em: 15/03/2023.

PATKI, Priti Sudhir; KELKAR, Vishakha. Support Vector Machine and various methods of Multi-Spectral satellite image classification. *IEEE. International Conference on Advances in Technology and Engineering (ICATE)*, Mumbai, India, p. 1-5, 2013. DOI 10.1109/ICAAdTE.2013.6524740. Disponível em: <https://ieeexplore.ieee.org/document/6524740>. Acesso em: 30/03/2023.

PINHEIRO, Évelyn Camila Casadias; RAMOS, Ana Paula Marques; JUNIOR, José Marcato. Validação da Aplicação de Imagens Planet à Regularização Ambiental de Imóveis Rurais no Mato Grosso do Sul. *Anuário do Instituto de Geociências - UFRJ*, [s. l.], 2019. DOI http://dx.doi.org/10.11137/2019_3_145_153. Disponível em: <https://revistas.ufrj.br/index.php/aigeo/article/view/31191>. Acesso em: 20/03/2023.



PLANET. Labs PBC. Planet Data. California, Estados Unidos. Disponível em: <https://developers.planet.com/docs/data/planetscope/>. Acesso em: 03/04/2023.

SHANAHAN, John F. et al. Use of remote sensing images to estimate the yield of corn grains. *Agronomy Journal* V. 93. no. 3. p. 583-589. 2001. Disponível em: SHANAHAN, John F. et al. Use of remote sensing images to estimate the yield of corn grains. *Agronomy Journal* V. 93. no. 3. p. 583-589. 2001. Acesso em: 04/04/2023.

TANGTHAIKWAN, Kanita Tangthaikwan; KEERATIPRANON, Narongdech; AGSORNINTARA, Adshariya. Multiclass Support Vector Machine for Classification Spatial Data from Satellite Image. *IEEE. 9th International Conference on Knowledge and Smart Technology (KST)*, Chonburi, Thailand, p. 1-5, 2017. DOI 10.1109/KST.2017.7886107. Disponível em: <https://ieeexplore.ieee.org/document/7886107>. Acesso em: 30/03/2023.

COMO CITAR ESTE TRABALHO

FAVERO, Isabella. JUNIOR, José Marcato. ARAÚJO, Márcio Santos. SOUZA, Mauricio de. NETO, João Batista Sarmiento dos Santos. Aprendizado de máquina aplicado no mapeamento do uso e cobertura do solo de assentamentos de reforma agrária no Acre. *Revista Tamoios, São Gonçalo*, v. 20, n. 2, p. 248-265, 2024. Disponível em: <https://doi.org/10.12957/tamoios.2024.77078>. Acesso em: DD MM. AAAA.