



AVALIAÇÃO DO DESEMPENHO DE TRÊS ALGORITMOS NA CLASSIFICAÇÃO DE USO DO SOLO A PARTIR DE GEOTECNOLOGIAS GRATUITAS

Miqueias Lima Duarte¹ Tatiana Acácio da Silva²

Resumo: O uso de sensores remotos aliados ao Sistema de Informação Geográfica tem sido de suma importância na classificação e monitoramento do uso e ocupação do solo, permitindo obter importantes produtos que podem subsidiar o planejamento e gestão do território. Assim, este trabalho teve por objetivo avaliar o desempenho dos classificadores supervisionados Minimum Distance-MD, o Maximum Likelihood-ML e o Spectral Angle Mapping-SAM na classificação do uso do solo em uma área do sul do estado do Amazonas através do uso de geotecnologias gratuitas. Utilizou-se uma imagem do sensor Sentinel-2, na qual foram identificadas seis classes de uso e ocupação. A qualidade dos classificadores foi testada a partir de três índices, exatidão global, Kappa e Tau. Apesar do bom desempenho apresentado pelos métodos utilizados, o método ML foi o mais eficiente, apresentando valores de exatidão global, índices Kappa e Tau superiores a 92%.

Palavras-chave: Cobertura do Solo. Classificadores. Sensoriamento remoto.

1 Introdução

Sabe-se que a utilização do solo de forma inadequada pode acarretar uma série de problemas ambientais, como mudanças climáticas, alterações no ciclo hidrológico e na perda de solo, afetando a estabilidade natural do ambiente. Desse modo, entender o uso e ocupação do solo e suas alterações ao longo do tempo e em relação ao espaço é de suma importância, uma vez que possibilita compreender as dinâmicas fisiográficas e ecológicas de uma região, auxiliando no planejamento.

A compreensão da dinâmica do uso do solo é de suma importância, uma vez que permite identificar suas relações com diferentes níveis de degradação, possibilitando estruturar métodos de recuperação destas áreas. Nesse contexto, o levantamento do uso do solo, em uma dada região, tornou-se um aspecto fundamental para a compreensão dos padrões de organização do espaço (BERNADI; DZEDZEJ; CARVALHO, 2007).

O uso de imagens orbitais em consonância com técnicas de geoprocessamento por meio dos Sistemas de Informações Geográficas (SIGs) mostram-se eficientes para detectar mudanças no uso e cobertura do solo e as alterações provocadas nas paisagens em um determinado local

(SANTOS et al., 2017). Stević et al. (2016) citam que a classificação de imagens de sensores orbitais consiste em uma metodologia utilizada para caracterização, comparação de paisagens, gestão ambiental e ordenamento do território com aplicação na modelagem e monitoramento das mudanças na paisagem.

Atualmente existem diversos métodos de classificação de imagens, esses métodos podem ser divididos segundo critérios distintos, tais como a classificação paramétrica e não-paramétrica, classificação espectral e espacial, e classificação supervisionada e não-supervisionada, sendo o último a forma mais difundida entre os usuários de SIG para o processamento de imagens (MENESES; ALMEIDA, 2012).

A classificação supervisionada normalmente apresenta maior precisão, ela é obtida a partir do conhecimento prévio das áreas e dos tipos de ocupação do solo que se pretendem levantar e classificar (OLIVEIRA et al., 2014). Por outro lado, a classificação não supervisionada é normalmente utilizada quando não se tem conhecimento da natureza das classes de alvos ou em análise exploratória. Nesse método, os pixels são agrupados em classes, de acordo com as suas características, determinadas a partir de cálculos estatísticos (MENESES; ALMEIDA, 2012).

¹E-mail: miqueiaseng@hotmail.com

²E-mail: tatiana.acacio@unesp.br

Dentre os métodos não supervisionados estão: IsoData e K-médias; e dentre os supervisionados estão: paralelepípedo, Mínima Distância, Máxima Verossimilhança, mapeamento por ângulo espectral, árvores de decisão, Redes Neurais Artificiais e, mais recentemente, o *Support Vector Machines* (PEREIRA; CENTENO, 2017).

Assim como existem diversos métodos de classificação, também existem diversos softwares utilizados para o processamento digital de imagens, dentre eles, o QGIS é um software de uso livre e aberto que tem se destacado por sua possibilidade de integração com outros softwares e disponibilidade de diferentes algoritmos e novos complementos que proporcionam uma maior automatização e agilidade no processamento de dados, surgindo como um forte aliado na avaliação do uso/coertura da terra (PEREIRA; GUIMARÃES; OLIVEIRA, 2018).

O complemento *Semi Automatic Classification Plugin* constitui um acessório desenvolvido especificadamente para o software QGIS, ele realiza a classificação semi-automática bem como supervisionada de imagens de sensoriamento remoto, foi desenvolvido por Congedo (2018). O Plugin

tem sido utilizado em várias pesquisas, apresentando resultados satisfatórios (BARROS; PAMBOUKIAN, 2017; MENESES; MENDES, 2017; SILVA et al., 2017; SANTOS; AUGUSTO; RICHTER, 2017).

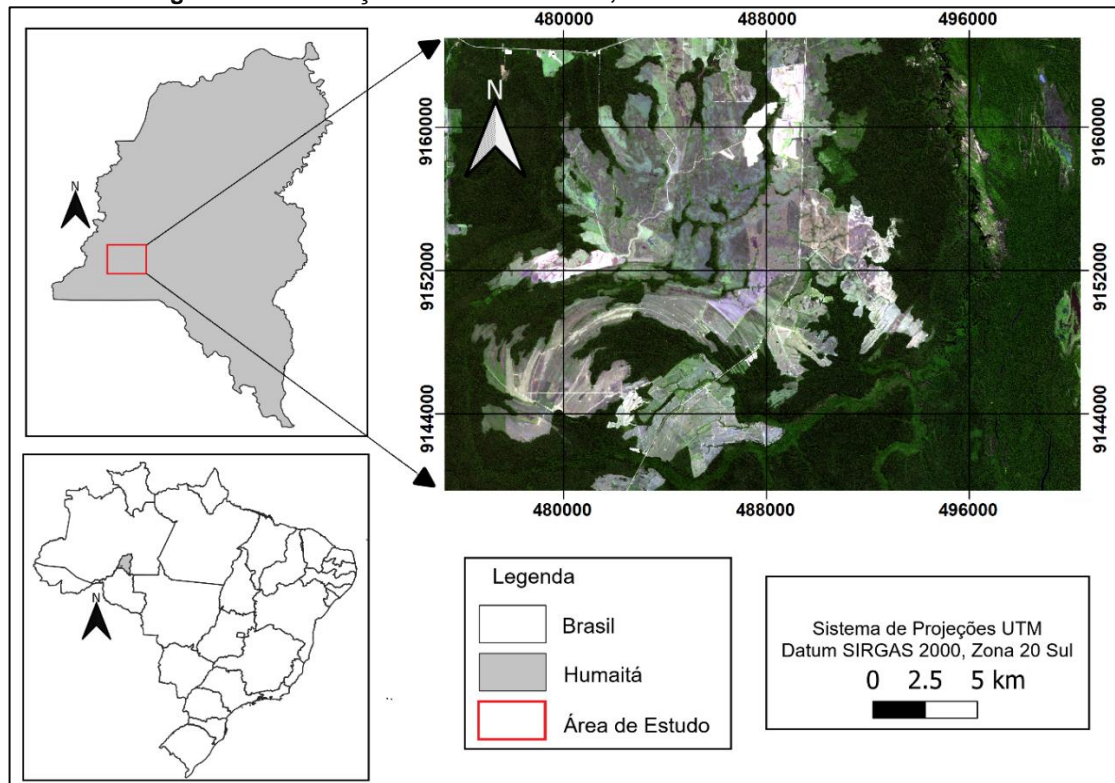
Nesse contexto, o objetivo deste trabalho é realizar a classificação do uso do solo em uma área no sul do Amazonas com uso de três técnicas de classificação supervisionada (Mínima Distância, Máxima Verossimilhança, Mapeamento por Ângulo Espectral) disponível na ferramenta *Semi Automatic Classification Plugin*, com base em uma imagem de média resolução espacial obtida pelo sensor Sentinel-2.

2 Metodologia

2.1 Localização e caracterização da área de estudo

A área onde foi desenvolvido este estudo fica localizado no município de Humaitá, sul do estado do Amazonas. Compreende um retângulo com área de 66.658,72 hectares que envolve áreas ocupadas por agricultura, pastagem, floresta e campo natural (Figura 1).

Figura 1 - Localização da área de estudo, no sul do estado do Amazonas



Fonte: Elaborado pelos autores a partir de limites estaduais e municipais (IBGE, 2018), e imagem do satélite Sentinel-2 (USGS, 2018)

Segundo a classificação climática de Köppen, o clima da região é do tipo Am, com precipitação anual variando de 2.250 a 2.750 mm e uma estação seca de pequena duração entre o mês de julho. A temperatura média anual varia de 24°C a 26°C, e umidade relativa do ar varia de 85 a 90%, e a altitude média é de 90 metros acima do nível do mar (MARTINS et al., 2006).

A vegetação predominante da região é da floresta tropical densa e/ou aberta, ocorrendo os campos naturais, quando a vegetação florestal se interrompe. Nessas áreas variações florísticas distintas, os campos naturais ocorrem de duas formas: Campo Alto e Campo Baixo, esses por sua vez, são compostos por gramíneo lenhoso (Campo Alto) e gramíneo (Campo Baixo) em grandes extensões (JORDÃO et al., 2015). As áreas de campos naturais, em especial,

ocupada por Campo Baixo, no período chuvoso apresentam-se encharcada em função do afloramento do lençol freático (DUARTE et al., 2016).

2.2 Base de dados

A classificação do uso do solo foi realizada com base em imagens do sensor Sentinel-2, no qual obteve a cena 20MMS com data de passagem 20 de julho de 2018, obtida junto ao Serviço Geológico dos Estados Unidos, a USGS (USGS, 2018).

Obteve todas as bandas disponibilizadas pelo sensor para geração da composição colorida e empilhamento de bandas para análise e interpretação dos tipos de alvos. A Tabela 1 apresenta as principais características espectrais do sensor Sentinel-2 em função de sua resolução espacial.

Tabela 1 - Faixas espectrais do sensor Sentinel-2 de acordo com a resolução espacial

| Resolução (m) | Nº da Banda | Nome da banda | Comprimento de onda (nm) |
|---------------|-------------|---------------|--------------------------|
| 10 | B02 | Blue | 490 |
| | B03 | Green | 560 |
| | B04 | Red | 665 |
| | B08 | NIR | 842 |
| 20 | B05 | Red Edge 1 | 705 |
| | B06 | Red Edge 2 | 740 |
| | B07 | Red Edge 3 | 783 |
| | B08A | Red Edge | 865 |
| | B11 | SWIR 1 | 1610 |
| | B12 | SWIR 2 | 2190 |
| 60 | B01 | Aerosol | 443 |
| | B09 | Water Vapor | 940 |
| | B10 | Cirrus | 1375 |

Fonte: Adaptado de ESA (2018).

2.3 Processamento de imagem

A classificação supervisionada foi realizada no software QGIS 3.2.0 "Borton" com a utilização do *Semi Automatic Classification Plugin* (versão 6.2.2 – Greenbelt), as etapas seguidas na classificação, e demais funções do plugin encontram-se descritas no manual do desenvolvedor (CONGEDO, 2018). A Figura 2 apresenta um fluxograma das principais etapas seguidas na classificação do uso do solo.

As imagens obtidas no USGS (formato JPEG) foram transformadas para o formato Geotiff, em seguida, foi realizado uma

reprojeção cartográfica tendo como base o sistema de projeções UTM (Universal Transversa de Mercator), zona 20 Sul.

Finalmente, foi realizado uma correção atmosférica pelo método DOS (*Dark Object Subtraction*) para correção do espalhamento atmosférico no qual a interferência atmosférica é estimada diretamente a partir dos Números Digitais (ND) da imagem de satélite, sendo ignorado a absorção atmosférica (SANCHES et al., 2011; SANTOS; AUGUSTO; RICHTER, 2017).

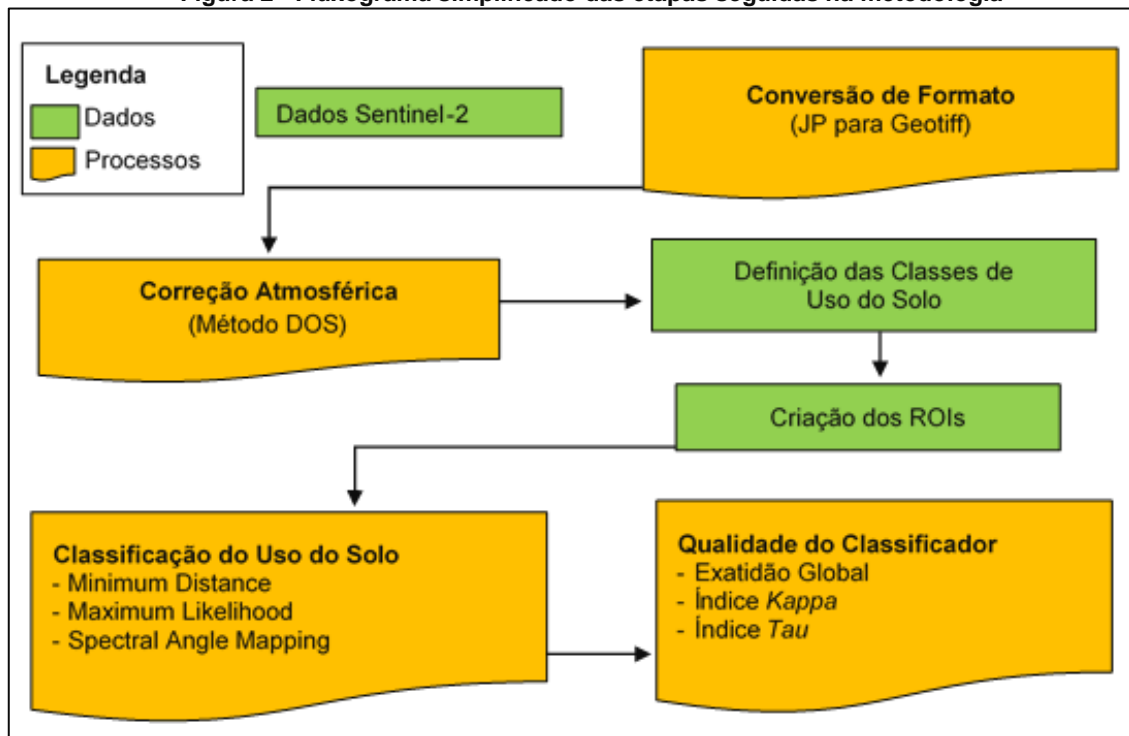
Posteriormente, foi realizado o empilhamento das bandas B02, B03, B04, B05, B06, B07, B08, B08A, B011, B012, conforme indicado pelo *Plugin*, para

composição colorida. Em seguida, foi realizado uma coleta amostras de treinamento do classificador em forma de polígonos, a partir da interpretação da imagem do Sentinel-2 (composição 4R 3G e 2B) diretamente na interface do software, levando em consideração as características de cada local que facilitassem a distinção entre as classes.

Foram coletados em média 20 amostras (20 polígonos) para cada classe (ROIs -*Regions of Interest*), sendo as dimensões dos polígonos de 50 a 100 pixels. Os mesmos ROIs de interesse foram utilizados para todos os métodos de classificação. As classes identificadas na área foram:

1. Vegetação densa: área identificadas com vegetação nativa arbórea densa.
2. Vegetação esparsa: áreas com vegetação arbórea nativa/ou não, em processo de regeneração arbustiva e/ou arbórea dispostas de forma esparsa.
3. Água: áreas ocupadas com água, com ausência de cobertura vegetal.
4. Solo exposto: áreas ocupadas por solo desnudo, com ausência de cobertura vegetal.
5. Gramínea esparsa: área ocupada por vegetação herbácea rasteira pouco densa.
6. Gramínea densa: área ocupada por vegetação herbácea alta, associado a cobertura arbustiva esparsa.

Figura 2 - Fluxograma simplificado das etapas seguidas na metodologia



Fonte: Autores (2019)

A classificação supervisionada foi realizada com base na assinatura espectral das amostras ROIs, comparando as características espectrais de cada pixel com as características espectrais das classes de cobertura do solo de referência. O *plugin* possui três algoritmos de classificação, o Minimum Distance-MD, o Maximum Likelihood-ML e o Spectral Angle Mapping-SAM.

O algoritmo MD calcula a distância espectral entre o vetor de medida para o pixel candidato e a média para cada assinatura de

classe. O método se utiliza da medida de distância Euclidiana. Cada pixel será incorporado a um agrupamento através da análise da medida de similaridade de distância Euclidiana, que é dada pela Equação 1.

$$D(x, n) = \sqrt{(x_i - m_i)^2} \quad (1)$$

Onde x_i corresponde o pixel amostrado, m_i a média das classes e n o número de bandas. O classificador compara a distância Euclidiana de cada pixel à média de

cada agrupamento. O pixel candidato é designado à classe com média mais próxima, isto é, à classe que apresenta a menor distância Euclidiana (MENESES; ALMEIDA, 2012).

Conforme descrito por South, Qi e Lusch (2004), o SAM utiliza os ângulos espectrais formados entre um espectro de referência e um espectro teste (pixel a ser classificado), a Equação 2 apresenta os componentes do classificador SAM.

$$a = \cos^{-1} \frac{\sum_{i=1}^b RE_i}{\sqrt{\sum_{i=1}^b (R_i)^2 \sum_{i=1}^b (E_i)^2}} \quad (2)$$

Onde α corresponde a função do arco-cosseno; b corresponde o número de bandas; R corresponde o espectro de referência; e E_i refere-se ao espectro teste. Nesse caso, quanto menor for o ângulo de α , maior é a similaridade entre o espectro de referência e um espectro teste (KRUSE et al., 1993).

O algoritmo ML calcula a probabilidade de distribuição para as classes, relacionadas ao teorema de Bayes, estimando se um pixel pertence a uma classe de cobertura do solo. Em particular, as distribuições de probabilidade para as classes são assumidas como forma de modelos normais multivariados (RICHARDS; JIA, 2006). A função discriminante descrita por Richards e Jia (2006), é calculada para cada pixel de acordo com a Equação 3.

$$gk(x) = \ln p(Ck) - \frac{1}{2} \ln |\Sigma k| - \frac{1}{2} (x - yk)^t \Sigma_k^{-1} (x - yk) \quad (3)$$

Onde Ck corresponde as classes, x o vetor de assinatura espectral de um pixel; $p(Ck)$ a probabilidade que a classes correta seja k ; $|\Sigma k|$ o determinante da matriz de covariância dos dados na classe k ; Σ_k^{-1} , corresponde ao inverso da matriz de covariância, e yk corresponde ao vetor de assinatura espectral da classe.

2.4 Validação da classificação

A última etapa da classificação digital de imagens corresponde a avaliação da qualidade dos classificadores (MENESES; ALMEIDA, 2012). A análise da acurácia da classificação foi realizada no próprio plugin com uso da ferramenta *Accuracy* que constrói a matriz de confusão.

O número de amostras necessárias para a verificação da validade da

classificação foi obtido conforme descrito por Passo (2013). Foi utilizado a função *Multiple ROI creation* para coleta de pontos de forma randômica, no qual obteve-se 300 amostras na área de estudo. Os critérios adotados para criação das amostras de validação foram os mesmos utilizados na coleta de amostras para classificação (dimensões dos polígonos de 50 a 100 pixels).

A análise da qualidade dos classificadores foi determinada a partir do índice *Kappa* (Equação 4) que é uma medida de concordância que fornece uma ideia do quanto às observações se afastem daquelas esperadas, fruto do acaso, indicando-nos assim o quão legítimo são as interpretações (MENESES; ALMEIDA, 2012).

$$K = \frac{\theta_1 - \theta_2}{1 - \theta_1} \quad (4)$$

Onde θ_1 corresponde ao índice global determinado pela Equação 5 e θ_2 corresponde ao índice global independente determinado pela Equação 6.

$$\theta_1 = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (5)$$

$$\theta_2 = \frac{\sum_{i=1}^c x_{ii}}{n^2} \quad (6)$$

Onde c corresponde o número de classes, x_{ii} os elementos da diagonal principal, ou seja, elementos classificados corretamente, e n o número total de amostras. Os valores do coeficiente *Kappa* variam de 0 a 1 (Tabela 2), sendo que, quanto mais próximo de 1 representa uma maior concordância entre os pontos de referência e as categorias classificadas (CONGALTON; GREEN, 1999).

Também foi calculado o coeficiente de concordância *Tau* (Equação 7), no qual baseia-se na probabilidade a priori, o que permite a obtenção do valor da concordância esperada antes de efetuar a checagem dos resultados de simulação de mapeamento (BRITES et al., 1996).

$$T_2 = \frac{P_0 - P_r}{1 - P_r} \quad (7)$$

Onde P_0 corresponde a exatidão global, $P_r = \frac{1}{M}$; sendo M o número de classes. Também foi calculado a exatidão do produtor (e_p) e a exatidão do usuário (e_u), conforme decrito por Story e Congalton (1986).

Tabela 2 - Critérios utilizados para classificação do índice Kappa

| Valor do Kappa | Concordância |
|--------------------|--------------|
| $K \leq 0$ | Péssimo |
| $0,0 < K \leq 0,2$ | Ruim |
| $0,2 < K \leq 0,4$ | Razoável |
| $0,4 < K \leq 0,6$ | Bom |
| $0,6 < K \leq 0,8$ | Muito Bom |
| $0,8 < K < 1,0$ | Excelente |

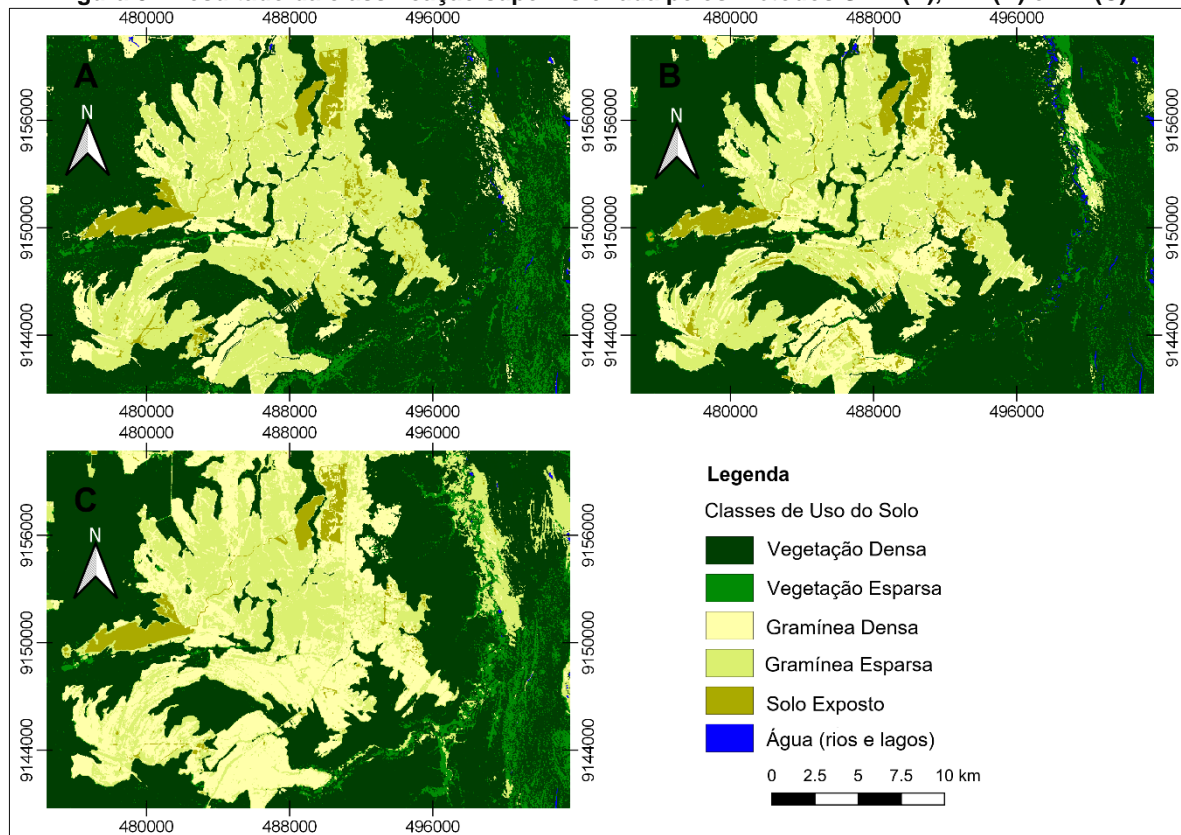
Fonte: Congalton e Green (1999)

3 Resultados

A Figura 3 apresenta os resultados obtidos para a classificação supervisionada do uso do solo pelos três métodos utilizados: SAM (A), MD (B) e ML (C). A interpretação

visual de imagens do Sentinel-2 possibilitou identificar e mapear seis classes de uso do solo, sendo elas: vegetação densa, vegetação esparsa, gramínea densa, gramínea esparsa, solo exposto e água.

Figura 3 - Resultado da classificação supervisionada pelos métodos SAM (A), MD (B) e ML (C)



Fonte: Autores (2019)

A porcentagem de área ocupada para cada classe de uso está apresentada na Figura 4. Na área mapeada, a classe Floresta densa é predominante, essa classe ocorre normalmente sobre tabuleiros com declividade de 0 a 25%, onde predominam os Cambissolos Háplicos, enquanto as áreas ocupadas por Floresta esparsa ocorrem sobre os Terraços Fluviais e Planícies Fluviais, com declividade que variam entre 0 a 3%,

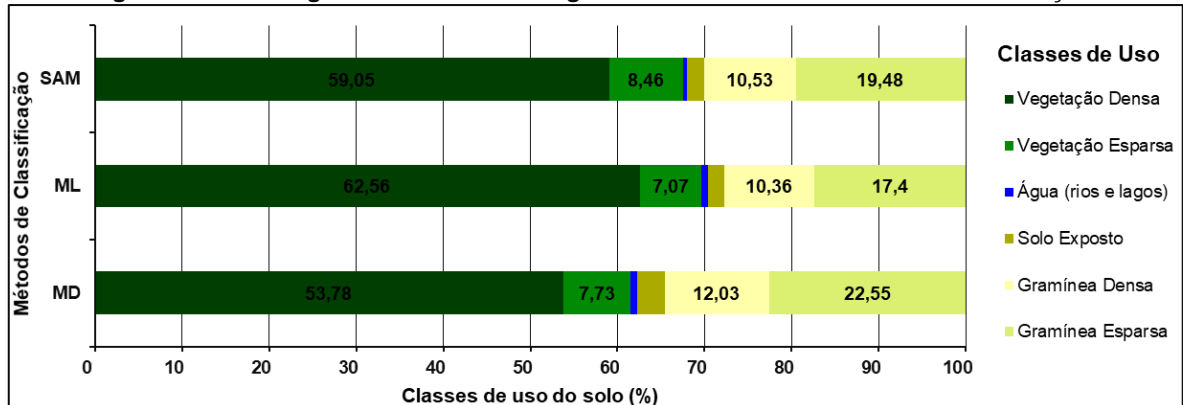
predominando os Argissolos Amarelos e Gleissolos Háplicos. As Gramíneas por sua vez ocorrem sobre Terraços Fluviais, com declividade variando entre 0 a 3%, no qual predominam os Plintossolos Háplicos.

Quando comparado com os demais classificadores, o método ML identificou a classe Floresta Densa com mais propriedade (62,56%), ocorrendo pouca confusão com a classe de uso mais próxima (Floresta Aberta).

Observa-se que os métodos SAM e ML identificaram maiores percentuais de áreas ocupadas por gramínea esparsa, essas áreas correspondem aos campos naturais, mais conhecidos como “Campos Amazônicos”, apresentando baixa densidade de vegetação em função da ocorrência de incêndios frequentes (JORDÃO et al., 2015).

Os percentuais identificados como solo exposto foram próximos em ambos os métodos, em destaque para as porções situadas no extremo norte e oeste da área de estudo (áreas de 6 km² em média). Esses locais correspondem áreas mecanizadas onde se desenvolvem o plantio de milho e soja em áreas de campos naturais no município de Humaitá.

Figura 4 - Percentagem de uso do solo segundo os diferentes métodos de classificação



Fonte: Autores (2019)

A Tabela 3 apresenta a matriz de confusão gerada para cada método utilizado, a exatidão do usuário e a exatidão do produtor para cada classe de uso, e a Tabela 4 apresenta o resultado dos índices obtidos para cada classificador. Segundo Foody (2002), a matriz de confusão tem sido utilizada principalmente para fornecer descrições básicas da precisão do mapa temático e para comparação de precisões. No entanto, ela também pode ser utilizada para extrair informações complementares para auxiliar na otimização de processos, diminuição de erros, que são consideravelmente mais úteis.

Os resultados obtidos demonstram que, os três métodos utilizados alcançaram uma precisão geral acima de 80%, que segundo a classificação de Congalton e Green (1999), os valores de coeficiente *Kappa* indicam que a classificação é de alta qualidade, ou seja, próximo a imagem de referência. Em destaque o método ML, sendo o que apresentou melhor performance na classificação do uso do solo, com índice de exatidão global de 0,9403, índice *Kappa* de 0,9291 e índice *Tau* de 0,9284.

O segundo melhor desempenho observado foi apresentado pelo método SAM, com índice de exatidão global de 0,9321,

índice *Kappa* de 0,9278 e índice *Tau* de 0,9185. O método MD apresentou desempenho inferior dentre os três métodos avaliados, sendo 0,8314; 0,8214 e 0,7977 para os índices de exatidão global, *Kappa* e *Tau* respectivamente (Tabela 4).

No que diz respeito ao erro acumulado de comissão (EC) (pixels incluídos erroneamente em uma classe quando deveriam ser assinalados a outra classe), o método ML apresentou o menor valor acumulado (38,39%), o que contribuiu para o alto valor do índice *Kappa*. Os demais métodos apresentaram 43,10% e 106,70% para SAM e MD respectivamente. Enquanto para a omissão (EO) (pixels omitidos de sua correta classe assinalados em outra) o método ML apresentou 570,96%, o SAM com 551,60% e o menor valor para o método MD (418,60%) conforme ilustrado na Figura 5.

Os problemas observados na separação entre as classes (1-2 e 2-1), pode ser explicado pela semelhança espectral existente entre os alvos, bem como a pequena variação entre os valores numéricos dos pixels, a existência de sobreposição entre classes e pela baixa resolução espacial e espectral do sensor, como descrito por Amaral et al. (2009).

REA – Revista de *estudos ambientais* (Online)
v.21, n. 1, p.6-16, jan./jun. 2019

Tabela 3 - Matriz de confusão do mapeamento de uso do solo com diferentes métodos

| Spectral Angle Mapping-SAM | | | | | | | |
|----------------------------|-------|-------|-------|-------|-------|-------|--------------|
| Classes | 1 | 2 | 3 | 4 | 5 | 6 | Total Coluna |
| 1 | 12117 | 768 | 0 | 0 | 0 | 110 | 12995 |
| 2 | 183 | 3260 | 0 | 0 | 0 | 0 | 3443 |
| 3 | 0 | 0 | 2792 | 0 | 0 | 0 | 2792 |
| 4 | 0 | 0 | 0 | 2417 | 2 | 0 | 2419 |
| 5 | 8 | 0 | 4 | 94 | 1441 | 22 | 1569 |
| 6 | 407 | 8 | 0 | 3 | 89 | 1298 | 1805 |
| Total Linha | 12715 | 4036 | 2796 | 2514 | 1532 | 1430 | 25023 |
| e_u | 95,29 | 80,77 | 99,85 | 96,14 | 94,06 | 90,76 | - |
| e_p | 93,24 | 93,24 | 93,24 | 93,24 | 93,24 | 93,24 | - |

| Maximum Likelihood-ML | | | | | | | |
|-----------------------|-------|-------|-------|-------|-------|-------|--------------|
| Classes | 1 | 2 | 3 | 4 | 5 | 6 | Total Coluna |
| 1 | 11143 | 270 | 0 | 0 | 7 | 279 | 11699 |
| 2 | 6 | 2513 | 0 | 0 | 0 | 0 | 2519 |
| 3 | 0 | 0 | 2796 | 0 | 0 | 0 | 2796 |
| 4 | 0 | 0 | 0 | 1808 | 0 | 0 | 1808 |
| 5 | 426 | 1 | 0 | 696 | 1397 | 3 | 2523 |
| 6 | 1140 | 1252 | 0 | 10 | 128 | 1148 | 3678 |
| Total Linha | 12715 | 4036 | 2796 | 2514 | 1532 | 1430 | 25023 |
| e_u | 98,28 | 72,62 | 98,78 | 98,76 | 93,99 | 99,16 | - |
| e_p | 91,91 | 91,91 | 91,91 | 91,91 | 91,91 | 91,91 | - |

| Minimum Distance-MD | | | | | | | |
|---------------------|-------|-------|--------|-------|-------|-------|--------------|
| Classes | 1 | 2 | 3 | 4 | 5 | 6 | Total Coluna |
| 1 | 12497 | 1055 | 34 | 0 | 0 | 10 | 13596 |
| 2 | 36 | 2931 | 0 | 0 | 0 | 0 | 2967 |
| 3 | 0 | 0 | 2762 | 0 | 0 | 0 | 2762 |
| 4 | 0 | 0 | 0 | 2483 | 0 | 0 | 2483 |
| 5 | 0 | 0 | 0 | 26 | 1440 | 2 | 1468 |
| 6 | 182 | 50 | 0 | 5 | 92 | 1418 | 1747 |
| Total Linha | 12715 | 4036 | 2796 | 2514 | 1532 | 1430 | 25023 |
| e_u | 87,63 | 62,26 | 100,00 | 71,91 | 91,18 | 80,27 | - |
| e_p | 95,24 | 95,24 | 95,24 | 95,24 | 95,24 | 95,24 | - |

*(1) Vegetação Densa; (2) Vegetação Esparsa; (3) Água; (4) Solo Exposto; (5) Gramínea Esparsa (6) Gramínea Densa, (e_u) Exatidão do usuário, (e_p) Exatidão do produtor.

Fonte: Autores (2019)


Tabela 4 - Valores obtidos para os índices de qualidade da classificação por diferentes métodos

| Classificadores | Exatidão Global | Coeficiente Kappa | Coeficiente Tau |
|-----------------|-----------------|-------------------|-----------------|
| ML | 0,9403 | 0,9291 | 0,9284 |
| MD | 0,8314 | 0,8214 | 0,7977 |
| SAM | 0,9321 | 0,9278 | 0,9185 |

*(ML) Maximum Likelihood; (MD) Minimum Distance; (SAM) Spectral Angle Mapping.

Fonte: Autores (2019)

Figura 5 - Erros acumulados de comissão (EC) e erros de omissão (EO) para cada método de classificação



Fonte: Autores (2019)

4 Conclusões

A partir da identificação e classificação do uso do solo por meio de três métodos de classificação disponível no *Semi Automatic Classification Plugin*, verificou-se o desempenho de cada classificador. A facilidade em manuseio da ferramenta, juntamente com a robustez do software corresponderam às expectativas do conjunto de geotecnologias de uso livre.

Com base nos resultados obtidos, observa-se que os métodos de classificação de uso do solo aplicado apresentaram bons desempenhos, alcançado uma precisão geral

acima de 80%, indicando que a classificação é de alta qualidade, ou seja, próximo a imagem de referência. Em destaque o método ML que apresentou melhor performance na classificação do uso do solo, com índice de exatidão global de 0,9403, índice Kappa de 0,9291 e índice *Tau* de 0,9284.

Os resultados obtidos demonstram que é possível realizar o mapeamento do uso do solo com boa qualidade utilizando dados de sensoriamento remoto e tecnologias de uso livre. Informações obtidas com uso dessas ferramentas podem dar subsídio a órgãos de planejamento territorial e ambiental sem a necessidade de custos.

5 Performance Evaluation of Three Algorithms on Land Use Classification from Free Geotechnologies

Abstract: *The use of remote sensors allied to the Geographic Information System has been of paramount importance in the classification and monitoring of land use and occupation, allowing to obtain important products that can support the planning and management of the territory. Thus, the aim of this study was evaluate the performance of the supervised classifiers Minimum Distance-MD, Maximum Likelihood-ML and Spectral Angle Mapping-SAM on the land use classification in a southern area of the state of Amazonas using free geotechnologies. An image of the Sentinel-2 sensor was used, in which six classes of use and occupation were identified. The quality of the classifiers was tested from the three indices, overall accuracy, Kappa and Tau. Despite the good performance presented by the methods, the ML method was the most efficient, presenting values of overall accuracy, Kappa and Tau indices above 92%.*

Keywords: Soil coverage, Classifiers, Remote sensing.

6 Referências

- AMARAL, M. V. F.; SOUZA, A. L.; SOARES, V. P.; SOARES, C. P. B.; LEITE, H. G.; MARTINS, S. V.; FILHO, E. I. F.; LANA, J. M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v.33, n.3, p.575-582, 2009.
- BARROS, E. O.; PAMBOUKIAN, S. V. D. Análise do desastre em mariana através da classificação supervisionada de imagens de sensoriamento remoto. **Revista Mackenzie de Engenharia e Computação**, v. 17, n. 1, p. 8-26, 2017.
- BERNADI, H. V. F.; DZEDZEJ, M.; CARVALHO, L. M. T. Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientada ao objeto em imagem QuickBird. *In: XIII Simpósio Brasileiro de Sensoriamento Remoto*, 13. Florianópolis/SC. **Anais [...]**. São José dos Campos: INPE, p. 5595-5602. 2007.
- BRITES, R. S.; SOARES, P. S.; RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificação de imagens orbitais. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 8, Salvador/BA. **Anais [...]**. São José dos Campos: INPE, 1996.
- CONGALTON, R.G.; GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Nova York, Boca Raton: **Lewis Publishers**, 137 p., 1999.
- CONGEDO, L. **Semi-Automatic Classification Plugin Documentation**. 2018. Disponível em: <https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-pt-br/latest/semiautomaticclassificationmanual-pt-br.pdf>, Acesso em: 05 jul. 2018.
- DUARTE, M. D.; ZANCHI, F. B.; NEVEZ, J. R. D.; COSTA, S. C.; JORDÃO, W. H. C. Vulnerabilidade à contaminação das águas subterrâneas no município de Humaitá, Amazonas, Brasil. **Revista Ambiente & Água**, v. 11, n. 2, 2016.
- ESA - European Space Agency. MultiSpectral Instrument (MSI) Overview. Disponível em: <https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>, Acesso em: 21 mar. 2018.
- FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environmen**. n. 80, p. 185– 201. 2002.
- JORDÃO, W. H. C.; ZANCHI, F. B.; FERREIRA, D. M. M.; PAGANI, C. H. P.; LUIZÃO, F. J.; NEVES, J. R. D.; DUARTE, M. L. Variabilidade do índice de área foliar em campos naturais e floresta de transição na região Sul do Amazonas. **Revista Ambiente & Água**, v. 10, n. 2, p. 363-375, 2015.
- KRUSE, F. A.; BOARDMAN, J. W.; LEFKOFF, A. B.; HEIDEBRECHT, K. B.; SHAPIRO, A.T.; BARLOON, P. J.; GOETZ, A. F. H. The spectral image processing system (SIPS) – interactive visualization and analysis of imaging spectrometer data. **Remote Sensing of Environment**, v. 44, p.145-163, 1993.
- MARTINS, G. C.; FERREIRA, M. M.; CURTI, N.; VITORINO, A. C. T.; SILVA, M. L. N. Campos nativos e matas adjacentes da região de Humaitá (AM): atributos diferenciais dos solos. **Ciência e Agrotecnologia**, v. 30, n. 2, 2006.
- MENESES, P. R.; ALMEIDA, de T. Introdução ao processamento de imagens de sensoriamento remoto. **UNB**, Brasília, 2012. 276p.
- MENEZES, W. A.; MENDES, L. D. A heterogeneidade e dinâmicas da paisagem na interação terra-atmosfera no município de Nova Iguaçu (RJ) a partir da aplicação de geotecnologias livres. **Revista Brasileira de Climatologia**. v. 21. p. 430-448, 2017.
- OLIVEIRA, G. C.; MARTINS, V. S.; FILHO, E. I. F.; XAVIER, F. V. Classificação Supervisionada como Ferramenta para Avaliação da Dinâmica do Uso e Cobertura do Solo. **Revista Enciclopédia Biosfera**, v. 10, n. 18, p. 924-935, 2014.
- PASSO, D. P. **Análise da qualidade de classificadores para identificação de alvos urbanos em imagens de alta resolução espacial - uma aplicação com as imagens do satélite Worldview II**. Dissertação (Mestrado em Geociências) - Universidade de Brasília/UNB, Brasília, 2013.
- PEREIRA, G. H. A.; CENTENO, J. A. S. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e Laser Scanner. **Boletim de Ciências Geodésicas**, v. 23, n. 2, p.268 - 283, 2017.
- PEREIRA, L. F.; GUIMARÃES, R. M. F.; OLIVEIRA R. R. M. Integrando geotecnologias simples e gratuitas para avaliar usos/coberturas da terra: QGIS e Google Earth Pro. **Journal of Environmental Analysis and Progress**. v. 3 n. 3. p. 250-264. 2018.
- RICHARDS, J. A., JIA, X. Remote Sensing Digital Image Analysis: An Introduction. Berlin. Germany: **Springer**. 4th Edition, 2006. 454p.
- SANCHES, I. D.; ANDRADE, R. G.; QUARTAROLI, C. F.; RODRIGUES, C. A. G. Análise comparativa de três métodos de correção atmosférica de imagens Landsat5-TM para obtenção de reflectância de superfície e NDVI *In: XV Simpósio Brasileiro de Sensoriamento Remoto*, 15. (SBSR). 2011, Curitiba/PR. **Anais [...]**. São José dos Campos: INPE, 2011. p. 7564-7571.

REA – Revista de *estudos ambientais* (Online)
v.21, n. 1, p.6-16, jan./jun. 2019

SANTOS, L. A. COSTA.; BATISTA, A. C.; NEVES, C. O. M.; CARVALHO, E. V.; SANTOS, M. M.; GIONGO, M. Análise multitemporal do uso e cobertura da terra em nove municípios do Sul do Tocantins, utilizando imagens Landsat. **Revista Agro@ambiente**, v. 11, n. 2, p. 111-118, 2017.

SANTOS, P. P.; AUGUSTO, R. C. RICHTER, M. Sentinels 2 - Procedimentos e potencial de utilização a partir de geotecnologias gratuitas. *In*: Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 18. (SBSR) Santo/SP. **Anais [...]**. São José dos Campos: INPE, 2017. p.7731-7737.

SILVA, C. V. T.; FILHO, J. C. R.; SILVA, P. M.; FILHO, L. L. C. A.; BRASIL, J. B. Caracterização morfométrica, uso e ocupação de uma bacia hidrográfica. **Revista Engenharia na Agricultura**. v.25, n.05, p.436-444, 2017.

SOUTH, S.; QI, J. and LUSCH, D. P. Optimal classification methods for mapping agricultural tillage practices. **Remote Sensing of Environment**. v. 91. p. 90-97. 2004.

STEVIĆ, D.; D.; B, I.; DOJČINOVIĆ, N.; JOKOVIĆ, J. Automated identification of land cover type using multispectral satellite images. **Energy and Buildings**, v. 115, p. 131-137, 2016.

STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, v. 52: p. 397-99, 1986.

USGS - UNITED STATES GEOLOGICAL SURVEY. Dados orbitais do Sentinel-2. Disponível em: <https://earthexplorer.usgs.gov>. Acesso em: 19 mar. 2018.

7 Agradecimentos

Os autores agradecem ao Laboratório de Engenharia Ambiental II – Geoprocessamento, do Instituto de Educação, Agricultura e Ambiente - IEAA, da Universidade Federal do Amazonas-UFAM, pelo espaço disponibilizado para o desenvolvimento da pesquisa, e o Conselho Nacional de Desenvolvimento Científico e Tecnológico-CNPq, pelo incentivo a pesquisa e concessão de bolsas de Pós-Graduação ao autor principal, ao *United States Geological Survey* (USGS), por ceder as imagens do Sentinel-2 utilizadas no trabalho.