

GEOBIA em imagem Rapideye para classificação do uso e cobertura da terra mediante *Self-Organizing Maps* em uma área da Bacia do Pitangui - PR

Kelly Lais Wiggers¹
Selma Regina Aranha Ribeiro¹

¹Universidade Estadual de Ponta Grossa – UEPG
84030-900 – Ponta Grossa – PR, Brasil
kellylaiswiggers@hotmail.com, selmar.aranha@gmail.com

Abstract. This meta paper explores the GEOBIA (Image Analysis Based on Geographic Objects) in order to obtain the input vectors for training Artificial Neural Network (ANN) through Self-Organizing Maps (SOM), for classifying patterns of land use. Pre-processing required in remote sensing images, and then the targets with their descriptors are performed. The feature selection is taken from PCA (Principal Component Analysis) culminating in the export of vectors with descriptors. The validation was ranked in some segments, with a kappa index of 0.9, underlining a rating of excellent quality, satisfactory result for the first tests with the SOM.

Keywords: remote sensing, image processing, artificial neural network sensoriamento remoto, processamento de imagens, redes neurais artificiais

1. Introdução

Muitas pesquisas que envolvem a evolução tecnológica estão relacionadas ao uso de sensores, o que facilitou a instrumentação dos equipamentos agrícolas, em suas atividades de gerenciamento da cultura, manejo do solo ou mesmo aplicação de insumos de forma adequada. Desta forma, as imagens digitais apresentam potencial para estudos da superfície terrestre, marítima, impactos ambientais, dentre outros.

Integrando técnicas matemáticas e estatísticas é possível discriminar as feições de superfícies mediante imagens de sensores remotos. Necessita-se, portanto, de análise quantitativa dos dados mediante sistemas computacionais, conhecida como classificação de imagens digitais.

As imagens digitais a serem classificadas são advindas das tecnologias de sensoriamento remoto (SR). Segundo Rudorff e Moreira (2002), sensoriamento remoto é uma tecnologia em constante crescimento e de grande potencial para a agricultura, pois por meio desta técnica é possível o levantamento de informações como, a estimativa de área plantada, produção agrícola, vigor vegetativo das culturas, além de fornecer subsídios para o manejo agrícola em nível de país, estado, município ou ainda em nível de sub-bacia hidrográfica ou fazenda.

Para realizar a categorização do uso do solo com imagens de sensores, é necessário exercer o processamento de imagens digitais (PDI). Desta forma, é realizada a melhoria da qualidade visual da imagem e, conseqüentemente, facilitando a interpretação. Um dos processamentos de PDI é a Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) é responsável por realizar a segmentação da imagem, a transforma em objetos geográficos, com os descritores espaciais, espectrais e de textura em formato vetorial com a possibilidade de exportação deste banco de dados para SIG.

Um método conhecido de classificação de imagens digitais, de modo geral e também de uso do solo, é a Rede Neural Artificial (RNA) Self Organizing Maps (SOM), que realiza aprendizagem não-supervisionada e apresenta bom desempenho se comparado à outros métodos de classificação não-supervisionado como o K-médias e ISODATA, visto que estes possuem algumas limitações bem como alto custo computacional.

Nesse contexto, o objetivo deste trabalho é classificar o uso e cobertura da terra de uma área da Bacia do Pitangui - PR, Brasil mediante GEOBIA e RNA SOM por recorte de imagem Rapideye.

2. Segmentação de imagens mediante GEOBIA

Uma das primeiras etapas em análise de imagens é a sua segmentação. A segmentação subdivide a imagem em suas partes ou objetos constituintes. O nível até o qual essa subdivisão deve ser realizada, depende do problema a ser resolvido. Ou seja, a segmentação deve finalizar quando os objetos de interesse na aplicação, tiverem sido isolados (GONZALEZ; WOODS, 2000).

O objetivo da segmentação é particionar a imagem em regiões, e assim, realizar a categorização das classes da imagem. Segundo Gonzales e Woods (2000) existem técnicas que são baseadas na formação das regiões diretamente, como: crescimento de regiões por agregação de pixels (agrupa os pixels ou sub-regiões em regiões maiores) e divisão e fusão de regiões (subdivide a imagem em um conjunto de regiões arbitrárias e disjuntas, e então realizar a divisão e/ou fusão das regiões).

Assim, a segmentação de imagens por meio da GEOBIA é a etapa essencial para problemas de reconhecimento de padrões e análise de cenas, uma vez que considera além das características espectrais da imagem, a textura e as formas. É necessário avaliar as características peculiares da imagem para escolher a técnica de segmentação que estabeleça bom resultado na classificação dos objetos de estudo.

Os métodos para realização da GEOBIA são obtidos no programa ENVI EX (<http://www.envi.com.br/index.php/modulos/fx>), no módulo FeatureExtraction, o qual pode realizar extração de informações em imagens de alta resolução baseado em características espaciais, espectrais e textura. Este módulo utiliza o algoritmo *Full Lambda Schedule Algorithm* (FLSA) e a abordagem orientada a objeto para segmentar e classificar imagens, sendo possível definir os valores de escala e de fusão dos segmentos ou regiões. O FLSA foi desenvolvido por Robbinson, Redding e Crisp (2002), e sua aplicação tornou-se comum, uma vez que, trata-se de um algoritmo que obtém ótimos resultados no processo de segmentação. Tendo como resultado o agrupamento de pixels em regiões, que devem estar espacialmente próximos, possuir características espectrais similares e informar os descritores de cada região em um banco de dados relacional.

Os descritores podem ainda ser exportados para arquivos vetoriais, e estes vetores são os dados de entrada para treinamento da RNA - SOM. Para tanto, a GEOBIA fornece grande quantidade de dados no banco relacional, ou seja, grande quantidade de descritores espaciais, espectrais e de textura, portanto com o intuito de reduzir a dimensionalidade de dados de entrada na RNA SOM é usada a análise de componentes principais (ACP).

3. Análise de Componentes Principais (ACP)

A preparação dos dados para futura classificação temática em RNA é uma tarefa essencial e também complexa. É necessário identificar quais dados apresentam maior relevância e que estes não sejam redundantes.

Em ACP, os dados são transformados em um novo sistema de coordenadas com eixos ortogonais. Assim, serão geradas n CPs a partir das n variáveis ortogonais. Cada CP pode ser analisada separadamente, e desta forma, ser escolhida quais CPs são mais importantes em cada eixo. Assim, a ACP é útil para reduzir a dimensionalidade de um conjunto de dados, bem como seleção de variáveis e ainda como realce de feições.

A partir da ACP, segundo Johnson e Wichern (2007), Tso e Mather (2009) e Jolliffe (2002), é possível explicar a variância-covariância de um conjunto de variáveis através de algumas

combinações lineares das mesmas.

4. Self-organizing Maps

Em processamento de imagens, as RNAs ganharam grande popularidade nos últimos anos como técnica alternativa e às vezes complementar às técnicas clássicas. Isto ocorreu pois, a maioria dos programas ou sistemas computacionais, voltados para o processamento de imagens digitais de sensoriamento remoto, realiza a classificação não-supervisionada baseada em métodos de agrupamentos particionais, como o K-médias e o ISODATA (GONÇALVES et al., 2008).

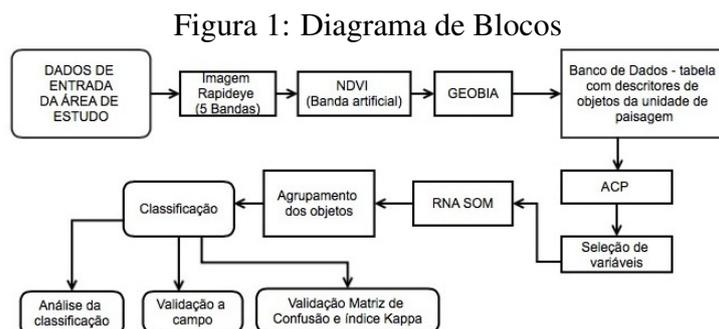
No contexto deste estudo, é analisado o desempenho da RNA não paramétrica SOM, para a classificação não-supervisionada de imagens de sensoriamento remoto. Na RNA SOM, os neurônios são organizados em nós numa grade a qual pode ser uni ou bidimensional. Os neurônios sintonizam-se seletivamente a vários padrões de entrada ou classes de padrões de entrada no decorrer do processo de aprendizagem. As localizações dos neurônios assim sintonizados ordenam-se entre si de forma que um sistema de coordenadas significativo, para diferentes características de entrada, é criado sobre a grade (HAYKIN, 2001).

Na aprendizagem não-supervisionada são oferecidas condições para realizar uma medida de distância entre camada de entrada e neurônios da grade, independente da qualidade da representação que a rede deve aprender, e os parâmetros livres da rede são otimizados em relação a esta medida (HAYKIN, 2001). Os pesquisadores Vicente et al. (2013), Lopes (2008), Gonçalves et al. (2008) descrevem a eficiência da rede não-supervisionada em suas pesquisas, relacionadas a mapeamento da cobertura terrestre de imagens de satélite, servindo como base da pesquisa.

Esta pesquisa foi realizada no ambiente computacional GeoSOM, desenvolvido pelos pesquisadores Fernando José Ferreira Lucas Bação e Victor José de Almeida e Sousa Lobo, com RNA SOM baseada na implementação com a caixa de ferramentas SOM para Matlab 5 (versão 2), desenvolvida por Vesanto et al (2000) na Helsinki University of Technology – Finlândia e contém funções para criação, visualização e análise de RNA SOM.

5. Material e métodos

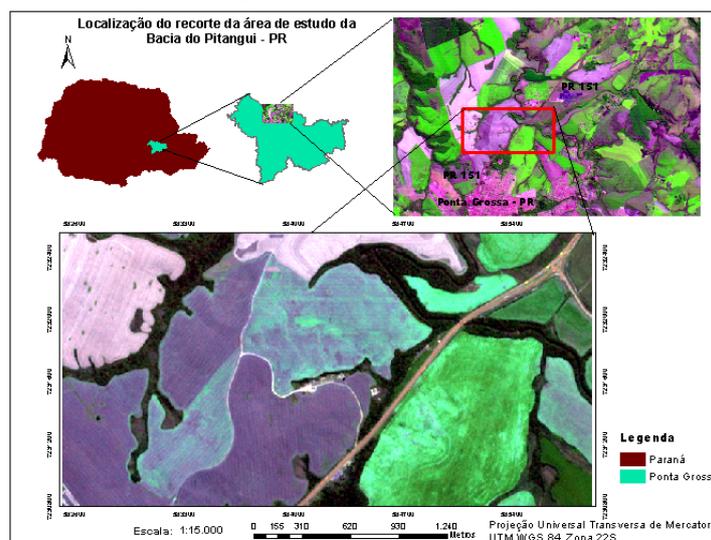
No diagrama de blocos da figura 1 é possível ver as etapas da pesquisa, a fim de alcançar o objetivo proposto e concluir o estudo. A imagem utilizada é a Rapideye ortorretificada, obtida em agosto de 2012, cedida pelo Departamento de Geografia pela Universidade Estadual de Ponta Grossa. Ela possui 5 metros de resolução espacial, resolução radiométrica de 12 bits, resolução temporal de 1 dia, e possui 5 bandas espectrais, sendo azul, verde, vermelho, red-edge e infravermelho próximo.



Fonte: A autora

A área de estudo está localizada na Bacia Hidrográfica do Pitangui, no estado do Paraná, o qual compreende uma rede de drenagem que segue em direção ao interior do estado (oeste). Para eleger a unidade de paisagem deste estudo, foram analisados alguns atributos físicos distintos da região, para determinar diferentes tipos de cultivos e cobertura da terra. Desta forma, a área de estudo, ilustrada na figura 2, abrange o Segundo Planalto Paranaense, ao norte da cidade de Ponta Grossa e situa-se entre as coordenadas aproximadas 582.600m E 7.230.800m N à 585.400m E e 7.232.400m N, meridiano central - 51, totalizando 6.352m².

Figura 2: Área de estudo



Fonte: A autora

Neste trabalho calculou-se o NDVI por ser um índice (banda artificial) importante para o monitoramento da vegetação e é utilizado para construir perfis, sazonal e temporal, das atividades da vegetação e visa a redução de efeitos de iluminação topográfica bem como o realce de feições que podem não estar evidentes nas bandas espectrais e em suas composições coloridas.

Os índices de vegetação para Aksoy, Akçay e Wassenaar (2010), são medidas simples mas poderosa para identificação fotossintética ativa. Segundo Moreira e Shimabukuro (2004), são encontrados na literatura mais de cinquenta índices de vegetação, sendo que quase todos obtidos de medidas de radiância refletida nas faixas espectrais do vermelho e infravermelho próximo do espectro eletromagnético. O NDVI é dado pela equação (31) :

$$NDVI = \frac{NIR - VIS}{NIR + VIS} \quad (31)$$

em que NIR é a faixa espectral do infravermelho próximo e a VIS é a do vermelho, com valores obtidos entre -1 e 1.

Portanto, o intuito de incluir o NDVI no processamento da RNA SOM, juntamente com as 5 bandas espectrais, é na tentativa de incrementar a separação das classes de interesse. Ou seja, principalmente auxiliar (aumentar) a distinção de tipos de cultivos, cobertura florestal e corpos d'água.

A etapa GEOBIA, como já mencionada, tem por objetivo realizar o processo de segmentação e a geração do banco de dados com os descritores dos segmentos, que particiona a imagem em segmentos por meio do agrupamento de pixels vizinhos que contenham

similaridade em suas feições (brilho, textura, cor, dentre outros.). Os parâmetros para a segmentação da imagem estão na tabela 1:

Tabela 1: Configurações da extração de características por GEOBIA

Escala	Fusão	Algoritmo escala	Algoritmo fusão
61,7	70	Edge	FLSA

A definição destes parâmetros da tabela 1 são de suma importância para o sucesso da segmentação, portanto testes foram realizados e definiu-se o valor da escala (61,7), que controla o tamanho dos objetos, e utilizou-se o algoritmo *edge* que suprime as bordas dos segmentos com falhas, criando um resultado que pode variar entre segmentos mais suaves ou mais robustos. A próxima etapa é a fusão que agrega segmentos pequenos em maiores, o algoritmo usado foi o FLSA. O processo de segmentação gerou 42 descritores da imagem para os polígonos ou segmentos, correspondendo aos atributos espaciais, espectrais e de textura.

O próximo passo é a seleção de variáveis mediante a ACP. Foi utilizado o *software R*, sendo implementado um *script* com a função de componentes principais, para seleção das variáveis a serem utilizados no treinamento na rede.

Assim, foi encontrado o maior valor absoluto dos autovetores e sua variável correspondente, seguindo o método B4, proposto por Jolliffe (1973). As 21 variáveis selecionadas para treinamento foram: comprimento, fator forma, relação entre bandas, alongamento, retangularidade, direção principal, eixo menor, matiz, saturação, intervalo, entropia e variância da textura, média dos valores digitais das bandas 3 e 5, valores máximos das bandas 4 e 5, desvio padrão das bandas 1, 2, 3, 4, 5. Foi adicionado ao arquivo (banco de dados com os descritores selecionados na ACP) a média, máximo, mínimo e desvio padrão dos valores digitais da banda artificial, sendo estes os descritores correspondente ao NDVI. Para verificar a eficiência da seleção de atributos mediante ACP, primeiramente realizou-se testes utilizando todas as variáveis do banco de dados a fim de obter a classificação com as mesmas configurações da RNA SOM.

Foram elaborados, na RNA SOM, diferentes configurações de topologia, tamanho, treinamento, funções de vizinhança e aprendizado, até a obtenção de um mapa que fosse considerado adequado para análise de resultados, ou seja, que abordasse todas as classes de interesse identificadas pela fotointerpretação da área de estudo. Desta forma, as configurações utilizadas foram: grade 7x7, inicialização de pesos randômica, função de normalização equalização por histograma contínuo, taxa de aprendizagem linear e raio de vizinhança gaussiana. Destaca-se que, a separação das regiões foi realizada pelo intérprete, devido ao conhecimento das classes de interesse.

Após a etapa de agrupamento, as classes de cobertura e uso da terra obtidas pelo treinamento da SOM mediante a ferramenta GeoSOM são salvas em formato ".txt", e no fim de cada amostra é adicionada a classe que esta pertence. Desta forma, é possível realizar a função "join" no ArcMap, a qual adiciona ao mapa as classes obtidas pela classificação.

A classificação da área de estudo foram validadas mediante verdade terrestre (VT). A classes foram obtidas por meio de interpretação visual e conhecimento a campo de algumas regiões para gerar o mapa de referência com pontos de validação. Foram coletados 20 pontos amostrais, verificados mediante campo, para cada classe na área de estudo no *software ArcMap*. Estes pontos foram superpostos à imagem classificada, gerando uma matriz de confusão para avaliar o desempenho, bem como análise mediante índice kappa, exatidão do produtor e usuário.

6. Resultados e Discussão

A tabela 2 exibe os parâmetros utilizados no treinamento.

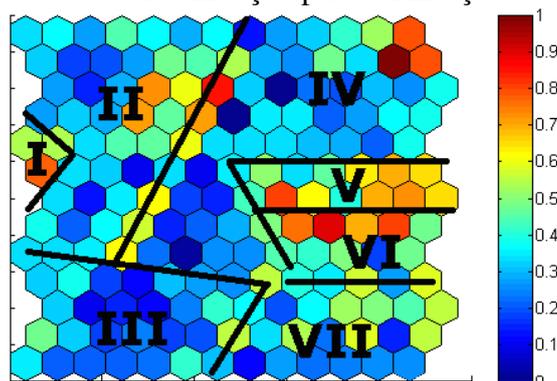
Tabela 2: Configurações da extração de características por GEOBIA

Treinamento	N. de épocas	Aprendizagem	Vizinhança
Ordenação	85	0,6	3
Convergência	200	0,06	2

As configurações de rede da tabela 2 geraram um erro topográfico de 0,89. O erro topográfico apresenta a proporção de todos os vetores de entrada para os quais o primeiro e o segundo neurônio vencedor não são unidades adjacentes. Também obteve-se o erro quantitativo de 0,04, o qual utiliza a matriz peso dos neurônios vencedores e a matriz de dados para o cálculo da distância euclidiana. Ele no geral, não é representativo, pois depende da dimensão dos dados, não sendo possível avaliar a qualidade do mapa obtido com relação a outros treinamentos.

Uma forma de visualizar os agrupamentos é apresentada graficamente mediante U_matriz obtida pela função som_umat , conforme figura 3.

Figura 3: U_matriz da classificação para verificação dos agrupamentos



Fonte: A autora

A U_matriz apresenta, mediante as unidades coloridas, as distâncias entre os agrupamentos. Verifica-se que a U_matriz é quase duas vezes maior que o mapa original criado, pois existe hexágonos adicionais no mapa, onde cada hexágono/retângulo, conforme topologia, delimita os agrupamentos. Para VESANTO et al. (2000) a variação de cores é representada conforme uma escala de distâncias, sendo do azul escuro ao vermelho. A cor azul escuro (0 a 0,4) representa os neurônios mais próximos, ou seja, os agrupamentos. As cores mais claras até o vermelho (0,5 a 1), representam a separação dos agrupamentos.

Assim, o mapa bidimensional 7x7 com 49 neurônios na camada de saída, 2489 segmentos (vetores de entrada), apresentou o resultado exibido na figura 3. É possível observar a separação em 7 regiões na figura 3 mediante linhas pretas, que exibem a ideia dos agrupamentos, os quais são representados por hexágonos mais claros (aproximadamente 0,5 a 1), conforme é mostrado na legenda das distâncias.

Como mencionado na metodologia, após o treinamento na ferramenta GeoSOM para obter as classes agrupadas, especializou-se no *software* ArcMap e o resultado é apresentando na figura 4.

A partir das amostras de validação obtidas a campo, foi gerada a matriz de confusão para análise da classificação do uso e cobertura da terra.

Figura 4: Classificação Final da área de estudo com ACP e NDVI



Fonte: A autora

Tabela 3: Matriz de confusão da classificação

Classe	C1.	C. d'água	C2	C3	Cob. Florestal	C4	Est. e contr.	Total
Cultivo 1	20	0	0	0	4	0	2	26
Corpos d'água	0	17	0	0	0	0	0	17
Cultivo 2	0	0	19	0	0	0	0	19
Cultivo 3	0	0	1	19	0	0	0	20
Cob. Florestal	0	3	0	1	16	0	0	20
Cultivo 4	0	0	0	0	0	20	1	21
Estr. e const.	0	0	0	0	0	0	17	17
Total	20	20	20	20	20	20	20	140
Ac. produtor (%)	100	85	95	95	80	100	85	
Ac. usuário (%)	76,92	100	100	95	80	95,23	100	

*Ac = acurácia, C1 = cultivo 1, C2 = cultivo 2, C3 = cultivo 3, C4 = cultivo 4, Est. e contr. = Estradas e construções, C. d'água = Corpos d'água, Cob. Florestal = Cobertura Florestal.

Verificou-se na matriz de confusão da tabela 3 que uma amostra pertencente ao cultivo 2 foi classificado como cultivo 3. Houve pequena confusão entre as amostras de corpos d'água com cobertura florestal, provavelmente devido a proximidade entre as classes e região pertencente, ou seja, a sombra que a cobertura florestal faz na água, alterando a sua intensidade. Os cultivos 1 e 4 foram corretamente classificados nas amostras coletadas para validação, pois a RNA SOM conseguiu discriminar estas classes. Entre as classes estradas e construções e o cultivo 1 os erros foram de duas amostras, já para cultivo 4 foi uma amostra. Para esta classe a separabilidade das estradas foram adequadas somente na PR 151 (estrada principal), já para os caminhos entre as culturas, estrada de "chão batido", a confusão espectral é evidente na figura 4.

Portanto, a acurácia global da classificação é de 91%, e o índice kappa calculado teve resultado em 0,9, considerado excelente conforme o valor de referência em Moreira (2011).

7. Conclusão

Com a capacidade da GEOBIA em particionar regiões (objetos) da imagem da área de estudo foi possível obter os descritores espectrais, espaciais e de textura, que, integrada à RNA SOM, identificar as classes de cobertura e uso do solo, sendo esse o principal objetivo do mapeamento do trabalho. Destaca-se a importância do processo de segmentação, mediante escolha dos parâmetros de escala e fusão de forma que não haja perda de informação dos objetos de interesse, auxiliando diretamente no processo de classificação.

Realizar seleção de atributos pela técnica de ACP possibilitou a redução da dimensionalidade dos dados, separando aqueles descritores mais significativos no banco de dados pela GEOBIA. Assim, verificou-se que, com as 21 variáveis selecionadas, o processo de classificação obteve melhores resultados daqueles testes utilizando todas as 42 variáveis.

Essa abordagem de RNA não supervisionada pode reduzir significativamente a complexidade da análise tornando possível a utilização de técnicas que são normalmente consideradas complexas para o processamento de imagens de SR. Além disso, o método apresenta outras vantagens tais como a integração de dados de diferentes escalas e origens. Apesar do método classificador ser não-supervisionado, o GeoSOM possibilitou mediante a *U_matriz* a definição dos agrupamentos e também a separabilidade de um mesmo cultivo em ciclos fenológicos diferentes, sendo cultivos 1 e 3.

A *U_matriz* auxiliou para a visualização dos agrupamentos, bem como verificar as principais interferências dos atributos de GEOBIA e o NDVI no decorrer do aprendizado da rede. Desta forma, foi possível visualizar os segmentos que foram agrupados em tais regiões, facilitando a interpretação e validação dos resultados.

O conhecimento a campo auxiliou na seleção das amostras para validação da classificação de uso e cobertura da terra, o que verificou-se o índice kappa com valor de 0,90 sendo este um resultado excelente conforme os valores de referência, destacando a eficiência dos métodos utilizados no objetivo de estudo.

8. Agradecimento

À CAPES pela concessão da bolsa de estudos.

Referências

- AKSOY, S.; AKÇAY, H. G.; WASSENAAR, T. Automatic mapping of linear woody vegetation features in agricultural landscapes using. *IEEE Transactions on Geoscience and Remote Sensing*, v. 48, n. 1, p. 511 – 522, 2010.
- GONÇALVES, M. L. et al. Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. *Revista Brasileira de Cartografia (RBC)*, v. 60, p. 17–29, 2008.
- GONZALEZ, R.; WOODS, R. *Processamento de Imagens Digitais*. 3. ed. São Paulo: Edgard Blucher Ltda, 2000.
- HAYKIN, S. *Redes Neurais: princípios e prática*. 2. ed. Porto Alegre: Bookman, 2001.
- LOPES, L. H. M. Uso e cobertura do solo no município de tailândia- pa utilizando o tm/landsat e técnica de classificação não-supervisionada. *ENGEVISTA*, v. 10, n. 2, p. 126–132, 2008.
- MOREIRA, M. A. *Fundamentos do Sensoriamento e Metodologia de Aplicação*. 3. ed. [S.l.]: Editora UFV, 2011.
- MOREIRA, M. A.; SHIMABUKURO, Y. E. *Cálculo do índice de vegetação a partir do sensor AVHRR*. São Paulo, 2004. 79-101 p.
- ROBBINSON, D.; REDDING, N.; CRISP, D. *Implementation of a Fast Algorithm for Segmenting SAR Imagery*. [S.l.]: DSTO - Electronics and Surveillance Research Laboratory, 2002.
- RUDORFF, B. F. T.; MOREIRA, M. A. *Sensoriamento Remoto Aplicado à Agricultura*. São José dos Campos, 2002.
- VESANTO, J. et al. *SOM Toolbox for Matlab 5*. April 2000. Disponível em: <<http://www.cis.hut.fi/projects/somtoolbox>>.
- VICENTE, L. E. et al. Mapeamento de características de solos tropicais utilizando self-organizing map aplicado à dados hiperespectrais. In: *nais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*. Foz do Iguaçu: [s.n.], 2013.