

Mineração de dados de sensoriamento remoto para detecção e classificação de áreas de pastagem na Amazônia Legal

Alana Kasahara Neves¹
Thales Sehn Körting¹
Cesare Di Girolamo Neto¹
Leila Maria Garcia Fonseca¹

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
{alana.neves; thales.korting; cesare.neto; leila.fonseca}@inpe.br

Abstract. Most of deforested areas in the Brazilian Amazon are occupied by pasture lands. The main cause of pasture degradation in this region is related to the condition of vegetation cover because of the fast regrowth and the competition with invasive plants. The aim of this study is to semi-automatically detect and classify patterns of pasture lands in the Legal Amazon, using time series of remote sensing images and data mining techniques, according to the conditions of the vegetation cover. The study site is the path/row 001/67 from Landsat 8 satellite. 28 images of surface reflectance, from 2013 to 2015, were used to construct the time series. Two classification methods were used: per pixel and object based. The following features were extracted from each image: vegetation indexes, fractions from the Spectral Linear Unmixing Model and components from the Tasseled Cap Transformation. The first step of the classification consisted in identifying pasture pattern, distinguishing class Pasture from Vegetation and Others. Later on, the pasture areas were reclassified into Clear Pasture (herbaceous pasture) and Dirty Pasture (shrubby pasture). In order to better evaluate the results, a classification procedure involving all classes was performed. The classification was validated by visual interpretation of a high spatial resolution image (RapidEye). The best accuracy was obtained on the object based approach, where it reached around 90%. Considering the per-pixel approach, it was difficult to identify some pasture due to the great amount of mixed elements in the images, like patterns of grass, tree, bush and others.

Palavras-chave: pasture, data mining, time series, pastagem, mineração de dados, série temporal.

1. Introdução

Estima-se que uma área de 751.340 km² tenha sido desmatada na Amazônia Legal até 2012, o que corresponde a 18,5% do total de floresta disponível inicialmente (INPE, 2013). O desflorestamento na Amazônia varia de acordo com as forças econômicas e os atores sociais relacionados e pode estar associado a diversas causas, das quais se pode destacar a construção de estradas, agricultura, pecuária e especulação de terra (FEARNSIDE, 2006). A conversão da cobertura florestal para outros usos do solo é responsável por diversos impactos ambientais, como alteração do ciclo de carbono, mudanças no regime hidrológico, erosão do solo e perda de biodiversidade (ASNER *et al.*, 2004).

A maior porcentagem de áreas desflorestadas na Amazônia é ocupada por pastagens (INPE, 2013). A pecuária na Amazônia e no Brasil é praticada predominantemente de forma extensiva, na qual a criação dos rebanhos é realizada em áreas de pastagens, sendo o manejo e monitoramento dessas áreas fundamentais para o controle do desflorestamento e da emissão de gases do efeito estufa (AGUIAR, 2013).

Embora haja esforços no sentido de manter a produtividade das pastagens, geralmente nota-se progressiva degradação a partir de 5 a 15 anos de uso da pastagem. A degradação da pastagem pode ser definida como a perda da produtividade de forrageiras e da capacidade de recuperação natural da pastagem, com qualidade insuficiente para a produção animal e superação dos efeitos causados por pragas, doenças e plantas invasoras (ZIMMER *et al.*, 2012). Na região amazônica, a principal causa da degradação das pastagens está associada às condições da cobertura vegetal, devido ao rápido processo de sucessão secundária e à competição com plantas invasoras (ASNER *et al.*, 2004; AGUIAR, 2013).

Contribuindo para o conhecimento da dinâmica de pastagens, o projeto TerraClass (Mapeamento do Uso e Cobertura da Terra nas Áreas Desflorestadas da Amazônia Legal) mapeia visualmente, a cada dois anos, as áreas de pastagens na Amazônia de acordo com cinco classes de interesse: pasto limpo, pasto sujo, regeneração com pasto, pasto com solo exposto e mosaico de ocupações (COUTINHO *et al.*, 2013). Em outra tentativa de classificação de pastagens, Ruffin *et al.* (2015) exploraram o potencial de séries temporais de imagens TM do satélite Landsat para caracterizar a qualidade de pastagens na Amazônia, em Novo Progresso – PA. Os autores utilizaram métricas da componente *wetness* (TCW) da transformação *tasseled cap* em uma série temporal de imagens de 1984 a 2012 e identificaram dois estágios de sucessão em pastagens: um dominado por gramíneas (pasto limpo, em boas condições) e outro dominado por plantas invasoras (vegetação degradada). A alta variabilidade do TCW nos dois estágios de sucessão indicou a existência de transições graduais entre os dois estágios ao longo do tempo (RUFFIN *et al.*, 2015).

Assim, trabalhos anteriores mostraram a viabilidade da utilização de séries temporais de imagens de sensoriamento remoto para caracterizar pastagens na Amazônia. Além disso, as técnicas de mineração de dados podem ser também relevantes nesta caracterização, uma vez que são capazes de extrair padrões, correlações e tendências dos dados por meio da aplicação de algoritmos (FAYYAD *et al.*, 1996). Portanto, esse trabalho teve como objetivo detectar áreas de pastagem e classificá-las de forma semi-automática, com base em séries temporais e mineração de dados, de acordo com as condições da cobertura vegetal.

2. Metodologia de Trabalho

2.1 Área de estudo

A área de estudo (Figura 1) escolhida para o trabalho consiste na porção brasileira da órbita/ponto 001/067 do satélite Landsat 8. A cena abrange partes dos estados de Rondônia, Acre e Amazonas e pertence ao bioma Amazônico.

A vegetação natural da Amazônia é composta predominantemente por floresta ombrófila densa, típica de florestas tropicais com alto grau de umidade. Seu clima é equatorial quente e úmido, com uma temperatura média entre 24°C e 26°C e umidade relativa em torno de 80% (FISCH *et al.*, 2014). A escolha desta região foi devido à importância da pecuária para a sua economia e, conseqüentemente, à intensa presença de pastagem.

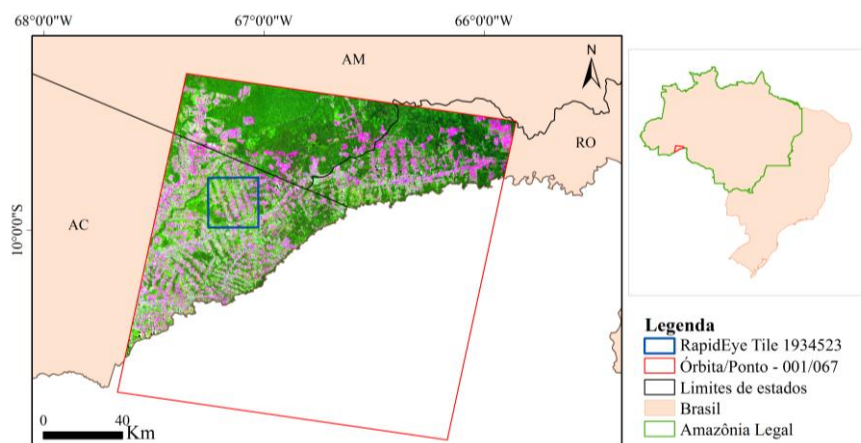


Figura 1. Área de Estudo.

2.2 Pré-processamento dos dados

Neste trabalho, foram utilizadas imagens do sensor OLI do satélite *Landsat 8* convertidas para valores de reflectância de superfície e disponíveis para *download* no *website*

<http://earthexplorer.usgs.gov/>. As imagens possuem resolução espacial de 30 m e resolução temporal de 16 dias.

As imagens correspondem ao período entre abril de 2013 e dezembro de 2015. Aquelas que possuíam cobertura de nuvem superior a 30% foram excluídas, de forma que 28 imagens foram usadas para compor a série temporal. Nessas 28 imagens, os *pixels* com nuvens e sombras de nuvens foram identificadas por meio do algoritmo FMask (ZHU e WOODCOCK, 2012) e assim excluídos. Para cada imagem, seis bandas foram utilizadas: B2 – *Blue* (0,45 – 0,51 μm), B3 – *Green* (0,53 – 0,59 μm), B4 – *Red* (0,64 – 0,67 μm), B5 – NIR (0,85 – 0,88 μm), B6 – SWIR 1 (1,57 – 1,65 μm) e B7 – SWIR 2 (2,11 – 2,29 μm).

Duas abordagens de análise de imagens foram testadas no trabalho: por *pixel* e baseada em objetos. Na primeira abordagem, as séries temporais foram compostas para cada *pixel*, utilizando as 28 imagens. Na abordagem baseada em objetos, a imagem do tempo médio (11/07/2014) foi utilizada na segmentação e criação dos objetos. A segmentação, baseada no método de crescimento de regiões (BAATZ e SCHÄPE, 2015), foi realizada no *software eCognition Developer 64 9.0.1*. Os parâmetros de escala, forma e compacidade adotados foram de 60, 0,5 e 0,8, respectivamente.

2.3 Extração e seleção de atributos

A partir das imagens em valores de reflectância, cinco índices de vegetação (IV) foram extraídos para cada imagem da série temporal: NDVI – *Normalized Difference Vegetation Index* (ROUSE JR. *et al.*, 1973), EVI – *Enhanced Vegetation Index* (HUETE *et al.*, 1997), EVI2 – *Two Band Enhanced Vegetation Index* (JIANG *et al.*, 2008), SAVI – *Soil-Adjusted Vegetation Index* (HUETE, 1988) e NDII – *Normalized Difference Infrared Index* (HARDISKY *et al.*, 1983).

Para cada imagem, quatro componentes foram extraídos a partir do Modelo Linear de Mistura Espectral – MLME (SHIMABUKURO e SMITH, 1991): Vegetação, Solo, *non photo-synthetic vegetation* (NPV) e água/sombra. Esta última foi descartada e as três primeiras foram utilizadas posteriormente na mineração de dados.

Além destes, foi realizada a transformação *tasseled cap* – TCT (KAUTH e THOMAS, 1976) para agregar as informações das bandas do sensor OLI em componentes que se relacionam com as características físicas da imagem. A transformação foi executada de acordo com os coeficientes propostos por Baig *et al.* (2014) para o sensor OLI. As componentes resultantes da TCT foram *Greenness*, *Brightness* e *Wetness*. A extração dos IVs, das frações de MLME e dos componentes da TCT foi feita na linguagem R (IHAKA e GENTLEMAN, 1996).

Na abordagem baseada em objetos, para cada segmento, os atributos descritos acima foram representados pela integração dos valores de determinado atributo, por meio da média dos valores de todos os *pixels* contidos naquele segmento. Além disso, outros atributos espectrais e texturais também foram calculados: Brilho, Média da Banda, Máxima Diferença, GLCM *Entropy*, GLCM *Dissimilarity*, GLCM *Ang. 2nd Mom.*, GLCM *Contrast*, GLCM *Homogeneity* e GLCM *Correlation* (ALBREGTSEN, 2008).

Após a fase de extração dos atributos, o processo de seleção dos atributos foi realizado para reduzir o conjunto de dados e, assim, selecionar os atributos relevantes para a detecção e classificação de áreas de pastagens. Neste caso, foi utilizado o método de Seleção Baseada em Correlação (CFS – *Correlation Feature Selection*) (HALL, 1999) no *software Weka 3.6* (HALL *et al.*, 2009).

2.4 Detecção de pastagens

A detecção de pastagens consistiu na primeira etapa de classificação, na qual foram diferenciadas as *Pastagens* das classes de *Vegetação* (floresta e vegetação secundária) e

Outros (áreas agrícolas, áreas urbanas, mineração, etc). Em ambas as abordagens, os seguintes algoritmos supervisionados de classificação foram utilizados: J48 – árvore de decisão (QUINLAN, 2014), *Random Forest* (BREIMAN, 2001) e *Multilayer Perceptron (MLP)* – rede neural (HAYKIN, 2009). Utilizou-se o *software Weka 3.6* nesta etapa de detecção.

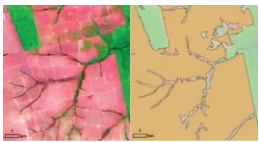

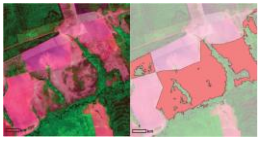

Foram extraídas 500 amostras dos dados de referência obtidos em imagem *RapidEye* para a construção dos modelos de classificação.

2.5 Classificação

Os pixels e objetos identificados como pastagem na etapa anterior foram transformados em conjunto de dados de entrada para a classificação das áreas de pastagens em duas classes (Tabela 1): *Pasto Limpo* e *Pasto Sujo*. A diferenciação entre *Pasto Limpo* e *Pasto Sujo* ocorreu em apenas uma imagem da série temporal, referente à 11/07/2014, pois existe uma considerável variação da condição da pastagem ao longo de um ano, conforme observado por Rufin *et al.* 2015.

A escolha das classes foi baseada na legenda adotada pelo projeto TerraClass (COUTINHO *et al.*, 2013). Das três outras classes que abrangem áreas de pastagem no TerraClass (regeneração com pasto, pasto com solo exposto e mosaico de ocupações), a primeira foi incluída na classe de *Pasto Sujo* e as outras duas possuem áreas minoritárias e não foram consideradas. Os dois estágios de sucessão identificados por Rufin *et al.* (2015) em pastagens também foram considerados: *woody pasture* e *grass-dominated pasture*. Foram utilizados os mesmos classificadores e *software* da etapa de detecção.

Tabela 1. Tipologia das classes de pastagem.

Classe	Tipologia – Landsat*	Tipologia - Fotografia	Padrão
Pasto Limpo			Cor: magenta. Textura: lisa. Áreas (quase) totalmente cobertas por gramíneas. Baixa infestação por invasoras herbáceas e arbustivas e sem a presença de arbóreas.
Pasto Sujo			Cor: magenta e verde claro. Textura: lisa ou levemente rugosa. Grande concentração de arbustos e árvores. Envolvem diferentes estágios de degradação.

*Utilizou-se a composição falsa-cor R(SWIR)G(NIR)B(Vermelho). Fonte: Adaptada de Coutinho *et al.* (2013).

Além do método de detecção (3 classes) seguido da classificação (2 classes), na abordagem baseada em objetos também foi realizada uma classificação em uma única etapa. Essa etapa foi responsável pela separação das duas classes de interesse (*Pasto Limpo* e *Pasto Sujo*) das demais classes, resultando em uma classificação com 5 classes: *Pasto Limpo*, *Pasto Sujo*, *Floresta*, *Vegetação Secundária* e *Outros*.

2.6 Dados de referência e validação

A interpretação visual de imagem de alta resolução espacial (5m) do satélite *RapidEye* foi usada para a validação da classificação. A imagem adquirida em 11/07/2014, mesma data da imagem do sensor OLI utilizada para a segmentação, está disponível no geocatólogo do Ministério do Meio Ambiente (MMA) (<http://geocatalogo.mma.gov.br/>).

Os dados de referência foram usados na construção do conjunto de amostras nas etapas de detecção de pastagens e classificação. Para estimar a acurácia dos modelos de classificação pontos aleatórios foram gerados nas classificações e nos dados de referência e construídas matrizes de confusão. As amostras utilizadas para a construção dos modelos foram diferentes das amostras utilizadas para testar os modelos.

3. Resultados e discussão

A Tabela 2 apresenta as taxas de acerto na construção dos modelos dos três casos de classificação estudados neste trabalho. O Caso 1 consiste na classificação por pixel para discriminar Vegetação, Pastagem e Outros, seguida da diferenciação da Pastagem em Pasto Limpo e Pasto Sujo. O Caso 2 consiste na classificação baseada em objetos para discriminar as três classes, seguida da diferenciação das pastagens. Finalmente, o Caso 3 classifica a área de estudo nas classes Floresta, Vegetação Secundária, Pasto Limpo, Pasto Sujo e Outros em uma só etapa.

Tabela 2. Taxas de acerto (%) na construção dos modelos.

		Classificador		
		J48	<i>Random Forest</i>	MLP (Rede Neural)
(Caso 1) <i>Pixels</i>	3 Classes	82,94	83,53	82,94
	Tipos de Pastagem	72,44	75	78,21
(Caso 2) Objetos	3 Classes	84,24	85,2	83,99
	Tipos de Pastagem	78,25	79,15	76,46
(Caso 3) Objetos	5 Classes	65,1	68,59	65,46

Para os Casos 1 e 2, os três classificadores obtiveram desempenhos satisfatórios: na detecção de Pastagem, os classificadores J48, *Random Forest* e MLP apresentaram desempenho médio de 84,15%, 85,28% e 82,20%, respectivamente, considerando os conjuntos com e sem seleção de atributos. Já na etapa de classificação de Pasto Limpo e Pasto Sujo, os desempenhos médios foram de 75,29%, 77,35% e 77,62%, respectivamente. Houve uma pequena superioridade da taxa de acerto na classificação pelo algoritmo *Random Forest* (1,83% maior, em média, considerando todos os casos). Entretanto, o J48 gera uma única árvore de decisão para realizar a classificação (QUINLAN, 2014), facilitando a reprodutibilidade do método e a visualização da contribuição de cada atributo. Por esse motivo, as árvores de decisão geradas na construção dos modelos foram aplicadas no restante da imagem e foram obtidas as taxas de acerto apresentadas na Tabela 3. Além disso, para esse estudo, a seleção de atributos não apresentou vantagens, uma vez que os conjuntos obtidos na fase de seleção de atributos obtiveram desempenho inferior aos conjuntos completos.

O Caso 3 obteve as piores taxas de acerto (65,76%, em média), confirmando uma melhora de desempenho quando é possível detectar o padrão das áreas de pastagem e posteriormente separá-las de acordo com outro critério como, por exemplo, a condição da cobertura vegetal. Isso ocorre devido à consideração da relação de dependência entre as classes (só será Pasto Limpo ou Sujo um objeto já classificado como Pastagem). De acordo com Silla Jr. e Freitas (2011), a representação dessa dependência em uma classificação hierárquica é capaz de melhorar o poder de predição dos classificadores.

Tabela 3. Taxas de acerto (%) na validação dos modelos gerados pelo classificador J48.

Caso 1 (<i>pixels</i>):								
3 Classes - 81,75%				Tipos de Pastagem - 64,77%				
Classificado como (%):				Classificado como (%):				
	Vegetação	Pastagem	Outros		Pasto Limpo	Pasto Sujo		
	Vegetação	92,11	16,55	11,52	Pasto Limpo	61,50	12,82	
Ref.:	Pastagem	6,51	73,81	45,71	Ref.:	Pasto Sujo	30,75	71,25
	Outros	1,38	9,64	42,77		Outros	7,76	15,93
	Total	100	100	100	Total	100	100	

Caso 2 (objetos):

3 Classes - 90,09%				Tipos de Pastagem - 76,43%		
Classificado como (%):				Classificado como (%):		
	Vegetação	Pastagem	Outros		Pasto Limpo	Pasto Sujo
Ref.: Vegetação	94,07	5,51	7,12	Pasto Limpo	84,03	18,49
Pastagem	5,26	91,49	21,35	Pasto Sujo	10,32	70,95
Outros	0,67	3,00	71,54	Outros	5,66	10,56
Total	100	100	100	Total	100	100

Caso 3 (objetos):

5 Classes - 32,22%					
Classificado como:					
	Floresta	Pasto Limpo	Pasto Sujo	Vegetação Secundária	Outros
Ref.: Floresta	35,30	20,08	18,84	18,81	12,50
Pasto Limpo	20,70	35,67	26,44	21,29	30,36
Pasto Sujo	25,88	31,04	32,83	22,28	29,64
Veg. Sec.	11,28	5,06	11,85	27,72	8,21
Outros	6,84	8,15	10,03	9,90	19,29
Total	100	100	100	100	100

Ainda na Tabela 2, observa-se que as taxas de acerto da classificação hierárquica baseada em objetos (Caso 2) foram superiores daquelas por *pixel* (Caso 1). Na validação dos modelos (Tabela 3), a superioridade da classificação baseada em objetos para o estudo tornou-se mais explícita. No Caso 1, a taxa de acerto na detecção de pastagem foi de 81,75% e na classificação do Pasto Limpo e Sujo foi de 64,77%, enquanto no Caso 2 as taxas foram de 90,09% e 76,43%, respectivamente. Na Figura 2, as espacializações dos dados de referência e dos casos 1 e 2 de classificação podem ser vistas.

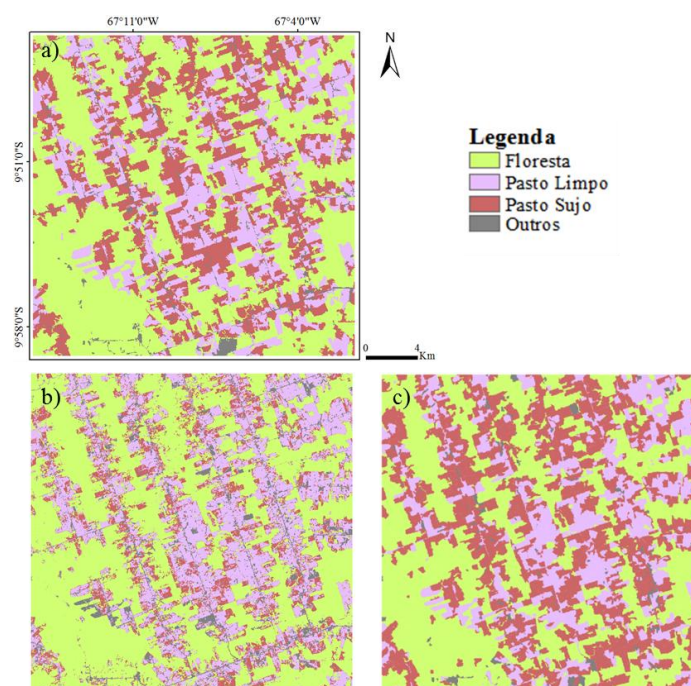


Figura 2. Espacializações da a) Referência, b) Caso 1 e c) Caso2.

Pode-se observar que a utilização da segmentação e a inclusão de outros parâmetros espectrais e parâmetros texturais na abordagem baseada em objetos foi fundamental para a melhoria da diferenciação entre Pastagem e Outros e entre Pasto Limpo e Pasto Sujo, principalmente. De acordo com Seyler (2002), as pastagens são difíceis de serem identificadas somente por meio de dados de sensoriamento remoto. Devido a grande quantidade de mistura de elementos em sua composição, como grama, árvore, arbustos e outros, as pastagens possuem padrões mais difíceis de serem caracterizados em séries temporais se comparadas com outras classes, como floresta e agricultura, por exemplo.

Nas árvores de decisão aplicadas, todos os cinco IVs, as três frações MLME e as três componentes da TCT aparecem relacionados a alguma imagem da série temporal (ex.: NDVI de julho de 2014, *Wetness* de setembro de 2014, etc.). Isto mostra a importância de cada um dos onze atributos escolhidos na identificação dos padrões de interesse para o estudo. As áreas de pastagens classificadas em Pasto Sujo apresentaram maiores valores de NDVI e menores valores de NPV, o que indica maiores concentrações de arbustos e árvores em sua composição, conforme já era esperado.

4. Conclusões

O Caso 2 atingiu 90,09% de acurácia na validação da classificação e obteve as maiores taxas de acerto dentre os demais casos. Ao comparar com os outros dois casos, pode-se observar que três aspectos foram fundamentais para este resultado: o uso da segmentação, a inclusão dos atributos texturais e a realização da classificação hierárquica.

Em trabalhos futuros, pretende-se testar a metodologia proposta para outras regiões da Amazônia Legal, uma vez que as particularidades de cada região podem modificar a dinâmica que as pastagens apresentam no tempo e espaço.

Referências Bibliográficas

- AGUIAR, D. A. **Séries temporais de imagens MODIS para avaliação de pastagens tropicais**. Tese (doutorado) do curso de pós-graduação em Sensoriamento Remoto. São José dos Campos: INPE, 2013. 143 p.
- ALBREGTSEN, F. Statistical texture measures computed from gray level cooccurrence matrices. **Image processing laboratory, department of informatics, university of oslo** 5 (2008).
- ASNER, G. P.; TOWNSEND, A. R.; BUSTAMANTES, M. M. C.; NARDOTO, G. B.; OLANDER, L. P. Pasture degradation in the central Amazon: linking changes in carbon and nutrient cycling with remote sensing. **Global Change Biology**. v. 10. 2004. p. 844-862.
- Baatz, M.; Schape, A. **Multiresolution Segmentation**: an optimization approach for high quality multi-scale image segmentation. 2015. Disponível em: <http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf>. 2015.
- BAIG, M. H. A.; ZHANG, L.; SHUAI, T.; TONG, Q. Derivation of a tasseled cap transformation based on Landsat 8 at satellite reflectance. **Remote Sensing Letters**. v.5, n.5. 2014. p. 423-431.
- BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.
- COUTINHO, A. C.; ALMEIDA, C.; VENTURIERI, A.; ESQUERDO, J. C. D. M.; SILVA, M. Projeto TerraClass: Uso e cobertura da terra nas áreas desflorestadas na Amazônia Legal. Brasília, DF: Embrapa; Belém: INPE, 2013.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v.17, n.3, p.37-54, jul., 1996.
- FEARNSIDE, P. M. Desmatamento na Amazônia: dinâmica, impactos e controle. **Acta Amazonica**. v. 36 (3). 2006. p.395-400.

FISCH, G.; MARENGO, J. A.; NOBRE, C. A. Clima da Amazônia. In: **Boletim Climanálise**. v. 29. n. 2. INPE. 2014.

HALL, M. A. Correlation-based feature selection for machine learning. 178p. Thesis (PhD on Computer Science) – Department of Computer Science, University of Waikato, Nova Zelândia. 1999.

HALL M.; FRANK, E., HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. **The WEKA Data Mining Software: An Update**. SIGKDD Explorations, Volume 11, Issue 1. 2009.

HARDISKY, M.A., KLEMAS, V., SMART, R.M. The influences of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. **Photogrammetric Engineering and Remote Sensing**. n. 49. 1983, p. 77–83.

HAYKIN, S. **Neural Networks and Learning Machines**. 3ed., Englewood Cliffs: Prentice- Hall. 2009.

HUETE, A. R. A soil adjusted vegetation index SAVI. **Remote Sensing of Environment**. v. 25, 1988, p. 295–309.

HUETE, A. R.; LIU, Q.Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v.59, n.3, p.440-451. 1997.

IHAKA, R.; GENTLEMAN, R. R: A language for data analysis and graphics. **Journal of Computational and Graphical Statistics**. v. 5. n. 3. p.299-314, 1996.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE), 2013. **Projeto de Monitoramento do Desflorestamento na Amazônia Legal – PRODES**. INPE. Disponível em: <<http://www.obt.inpe.br/prodes/index.php>>.

JIANG, Z.; HUETE, A.R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v.112, n.10, p.3833-3845. 2008.

KAUTH, R. J.; THOMAS, G. S. The tasseled cap – a graphic description of the spectral-temporal development of agricultural crops as seen in Landsat. In: **Symposium on Machine Processing of Remotely Sensed Data**. West Lafayette, Indiana, 1976, p.41-51.

QUINLAN, J. R. (2014). **C4. 5: programs for machine learning**. Elsevier.

ROUSE, J.W., HAAS, R.H., SCHELL, J.A., DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In: **Third ERTS Symposium**. NASA, 1973, p. 309–317.

RUFIN, P; MULLER, H.; PFLUGMACHER, D.; HOSTERT, P. Land use intensity trajectories on Amazonian pastures derived from Landsat time series. **International Journal of Applied Earth Observation and Geoinformation**, 41 (2015), p. 1-10.

SEYLER, F.; CHAPLOT, V.; MULLER, F.; CERRI, C. E. P.; BERNOUX, M.; BALLESTER, V.; FELLER, C.; CERRI, C. C. C. Pasture mapping by classification of Landsat TM images. Analysis of the spectral behavior of the pasture class in a real mediumscale environment: the case of the Piracicaba Catchment (12 400 km², Brazil). **International Journal of Remote Sensing**. v. 23. n. 23. p. 4985-5004, 2002.

SILLA JR., C. N. E FREITAS, A. A. A survey of hierarchical classification across different application domains. **Data Mining Knowledge Discovery**, 22 (1-2): p. 22–31. 2011.

SHIMABUKURO, Y. E.; SMITH, J. A. 1991 The least-squares mixing models to generate fractions images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, 29(1), pp. 16-20.

ZIMMER, A. H.; MACEDO, M. C. M.; KICHEL, A. N.; DE ALMEIDA, R. G. **Degradação, recuperação e renovação de pastagens**. Campo Grande, MS: Embrapa gado de corte, 2012.

ZHU, Z.; WOODCOCK, C.E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**. v. 118. 2012. p. 83–94.