

Comparação da acurácia de índices de vegetação aplicados a classificação de imagens do satélite Landsat 8

Anderson Paulo Rudke¹
Ana Carolina Freitas Xavier¹
Thais Fujita¹
Ronaldo Adriano Alves²
Rodrigo Augusto Ferreira de Souza³
Edmilson Dias de Freitas⁴
Jorge Alberto Martins¹

¹Universidade Tecnológica Federal do Paraná - UTFPR
Avenida dos Pioneiros, 3131 CEP 86036-370 - Londrina –PR, Brasil
{rudke, anaxavier, fujita}@alunos.utfpr.edu.br
jmartins@utfpr.edu.br

²Universidade Luterana do Brasil – CEUJI/ULBRA
Caixa Postal 21 - 76907-438 - Ji-Paraná- RO, Brasil
a.ronald.cad@gmail.com

³Universidade do Estado do Amazonas - UEA/CENA
Rua Sete, 11 CEP 69057-350 - Manaus – AM, Brasil
rafsouza@uea.edu.br

⁴Universidade de São Paulo - USP/CENA
Rua do Matão, 1226 CEP 05508-090 – São Paulo - SP, Brasil
efreitas@model.iag.usp.br

Abstract: The classification of soil use and coverage, as well as analysis of its changes are among most common applications for remote sensing. One of the most basic steps of the classification is the distinction of the vegetal cover in the other terrestrial surfaces. Landsat images are relevant sources of data in this analysis; and although there are several vegetation classification indices using Landsat data described in the literature, applications are limited by low accuracy in various situations. In this sense, the purpose of this study was to compare the available vegetation indexes and to identify the one that best applies to the classification of Landsat 5 and 8 satellite images, investigating vegetation indexes by leaf water content and leaf pigments. The values of the Normalized Difference Infrared Index (NDII), Simple Ratio (SR) and Visible Atmospherically Resistant Index (VARI) were evaluated for a specific region located in the Cerrado Biome. The performance of the vegetation index was compared with the performance of the Maximum Likelihood Classifier (MAXVER). The accuracy of the MAXVER classification was significantly higher than that of the vegetation index (Kappa - 0.95). Among the vegetation indexes, the classification of images was best applied to SR, demonstrating good agreement with the spectral targets, being the confusion between exposed and urban classes, and between the sparse and agricultural ranks classes, important sources of classification error.

Palavras-chave: Índice de Vegetação; Imagens Landsat; Classificação do uso e cobertura do solo; Sensoriamento Remoto.

1. Introdução

Estudos relacionados a impactos sobre os sistemas naturais e sua relação com atividades humanas é tema de ampla discussão científica. A vegetação está entre os recursos naturais mais submetidos a mudanças ao longo do tempo e do espaço, como consequência observam-se grandes variações relacionadas ao uso e ocupação do solo e outras formas de mudanças ambientais.

Além disso, o desflorestamento está ligado a diversas problemáticas, tais como: alterações climáticas (BONAN, 2008), impactos relacionados ao ciclo hidrológico (BROWN et al., 2005), perda da biodiversidade vegetal e animal (HE e HUBBELL, 2011), bem como aumento de doenças tropicais e erupções de novas doenças (OLSON et al., 2010).

Neste sentido, sensoriamento remoto tornou-se uma importante fonte de informação para analisar e fornecer dados sobre mudanças em diferentes recursos, em particular quanto à vegetação. Atualmente existem sensores de satélite com diferentes resoluções espaciais, temporais e espectrais disponíveis, entre os satélites mais utilizados em pesquisas ambientais encontra-se a série de satélites Landsat. Os dados destes sensores são amplamente utilizados para a classificação do uso e cobertura do solo. Os classificadores mais comumente utilizados podem ser agrupados em: supervisionados e não-supervisionados (LU e WENG, 2007).

Além disso, vários índices de vegetação têm sido desenvolvidos para a avaliação qualitativa da vegetação usando medidas espectrais (BANNARI et al., 1995). Em particular, os sensores com bandas espectrais do vermelho (RED) e infravermelho próximo (NIR) se enquadram bem ao monitoramento da vegetação uma vez que a diferença entre as faixas do vermelho e infravermelho próximo são tidas como forte indicador da quantidade de biomassa fotossinteticamente ativa (WULDER e FRNKLIN, 2003).

Embora haja um conjunto considerável de técnicas aplicadas à análise da vegetação descritas na literatura, a escolha entre elas é limitada por problemas de precisão. Técnicas de monitoramento e detecção de mudanças ambientais são susceptíveis a serem menos confiáveis quando classificadores de baixa precisão são utilizados (FEYISA et al., 2014).

Neste contexto, o objetivo desta pesquisa é comparar vários índices de vegetação e identificar o melhor índice aplicado a classificação de imagens do satélite Landsat8, utilizando índices de vegetação por conteúdo de água nas folhas e por pigmentos das folhas.

2. Metodologia de Trabalho

2.1 Área de Estudo

A área de estudo contém duas Unidades de Conservação (UC's) que se localizam próximo a área urbana do município de Assis (Figura 1). A área total da Estação Ecológica de Assis é de 13,12 km² e da Floresta Estadual de Assis de 28,16 km², ambas localizadas no Bioma cerrado. Segundo a classificação de Köppen o clima da região é caracterizado como temperado úmido com verão quente (cfa) (ALVARES et al., 2014),

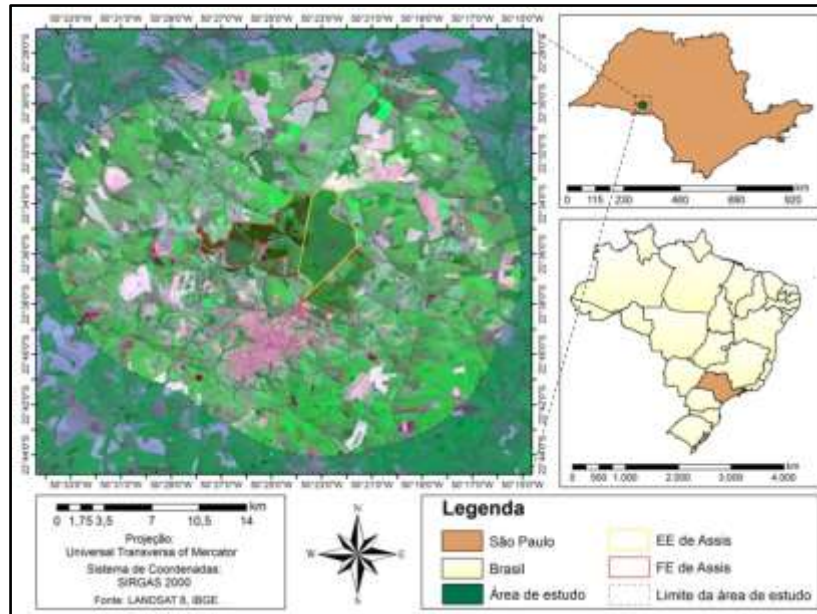


Figura 1. Mapa de localização da área de estudo.

2.2 Base de dados e processamento de imagem

As imagens orbitais dos sensores OLI e TIRS foram obtidas através do portal eletrônico do Serviço Geológico dos Estados Unidos (*U.S. Geological Survey*). A cena escolhida para avaliação pertence ao ponto 222 e orbita 76 (data de imageamento: 09 de junho de 2016).

Para comparar os resultados obtidos pelos índices de vegetação foi realizada uma classificação supervisionada, utilizando-se o classificador de Máxima Verossimilhança (MAXVER). As classificações foram realizadas com sete classes temáticas, sendo elas: urbano, solo exposto claro, solo exposto escuro, vegetação densa, vegetação esparsa, agropecuária e água. O Landsat 8 detém uma banda espectral com resolução de 15m (banda 7) a metodologia Fusão foi aplicada para melhorar a resolução das bandas utilizadas.

2.3 Índices de vegetação

As imagens do Satélite Landsat 8 foram utilizadas para adquirir índices de vegetação por conteúdo de água nas folhas NDII, NDWI e PSRI calculadas pelas equações: Eq. (1) (HUNT JR e ROCK, 1989), Eq. (2) (GAO, 1996) e Eq. (3) (MERZLYAK et al., 1999), respectivamente e por pigmentos de folhas EVI, NDVI, SR, VARI e VIg calculadas pela equações: Eq. (4) (HUETE et al., 2002), Eq. (5) (ROUSE JR et al., 1973), Eq. (6) (ROUSE JR et al., 1973), Eq. (7) (GITELSON et al., 2002) e Eq. (8) (GITELSON et al., 2002), respectivamente.

$$NDII = \frac{R_{nir} - R_{swir2}}{R_{nir} + R_{swir2}} \quad (1)$$

$$NDWI = \frac{R_{nir} - R_{swir1}}{R_{nir} + R_{swir1}} \quad (2)$$

$$PSRI = \frac{(R_{680} - R_{500})}{R_{750}} \quad (3)$$

$$EVI = 2,5 * \frac{R_{nir} - R_{red}}{R_{nir} + 6 * R_{red} - 7,5 * R_{blue} + 1} \quad (4)$$

$$NDVI = \frac{R_{nir} - R_{red}}{R_{nir} + R_{red}} \quad (5)$$

$$SR = \frac{R_{red}}{R_{nir}} \quad (6)$$

$$VARI = \frac{R_{green} - R_{red}}{R_{green} + R_{red} - R_{blue}} \quad (7)$$

$$VIg = \frac{R_{green} - R_{red}}{R_{green} + R_{red}} \quad (8)$$

Em que,

R_{nir} é a banda referente ao comprimento de onda do infravermelho próximo, R_{swir2} e R_{swir1} são referentes ao infravermelho de ondas próximas 2 e 1 respectivamente, R_{680} , R_{500} e R_{750} são bandas com comprimento de onda de 680nm, 500nm e 750nm respectivamente, R_{red} é a banda referente ao comprimento de onda vermelho, R_{green} é a banda referente ao comprimento de onda verde, R_{blue} é a banda referente ao comprimento de onda azul.

2.4 Avaliação dos classificadores

Imagens de alta resolução, obtidas através do Google Earth™, foram utilizadas para avaliar os produtos de classificação, sendo assim, fora escolhido um período de imageamento próximo ao realizado pelo Landsat - 24 de maio de 2016. Através da imagem do Google Earth foram distribuídos pontos de validação das classes definidas na classificação, sendo 20 amostras de solo exposto claro, 31 de solo exposto escuro, 14 de urbano, 36 de agropecuária, 7 de água, 28 de vegetação densa e 11 de vegetação esparsa.

Para avaliar a classificação das imagens foi utilizado o índice Kappa (SIEGEL e CASTELLAN, 1988), representada pela Eq. 9. O índice Kappa foi analisado por meio dos intervalos descritos por Landis e Koch (1977).

$$Kappa = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c (x_i + x + i)}{n^2 - \sum_{i=1}^c (x_i + x + i)} \quad (9)$$

Em que,

$\sum_{i=1}^c x_{ii}$ = somatório da diagonal da matriz de confusão; n = número de amostras coletadas; c = número do total de classes; x_i = soma da linha i da matriz de confusão; $x + i$ = soma da coluna i da matriz de confusão.

O Teste estatístico de McNemar foi aplicado para verificar se a classificação de MAXVER tem uma precisão significativamente maior em comparação com NDII, NDVI, SR e VARI no teste de continuidade de classes. O teste estatístico continuidade de McNemar foi calculado como mostrado na Eq. (10) (FEYISA et al., 2014).

$$\chi^2 = \frac{(|f_{12} - f_{21}| - 1)^2}{f_{12} + f_{21}} \quad (10)$$

Em que,

f_{12} e f_{21} representam as frequências de casos que são corretamente classificados por um método de classificação, mas erroneamente classificadas pelo outro.

3. Resultados e Discussão

Os índices de vegetação por pigmentos de folhas se mostraram mais eficientes do que os índices de vegetação por conteúdo de água nas folhas, como pode ser observado na Figura 2. Isto pode ter ocorrido devido ao mês de junho não ser característico de altos valores de precipitação (ICMBIO, 2010), o que representaria baixos teores de água no dossel das árvores.

Alguns índices de vegetação apresentaram resposta da distribuição das classes temáticas muito próximas, isto ocorreu devido à similaridade nos padrões de reflectância dos índices, portanto, tornando difícil a classificação da imagem, uma vez que a confusão entre as classes seria muito alta.

Através da Figura 2 é possível perceber que a maior confusão entre classes temáticas situasse nas classes solo exposto e urbano e entre as classes vegetação e agropecuária. As semelhanças espectrais entre solo exposto e urbano são consistentes com estudos anteriores (HEROLD et al., 2002; LU e WENG, 2004). A classe solo exposto escuro confunde-se

principalmente com a cerâmica escura, além disso, a confusão espectral entre as classes solo exposto claro e urbano se deve à similaridade de cor com concreto e cobertura metálica (CERQUEIRA e ALVES, 2010). Confusão entre as classes vegetação e agropecuária também já foram citadas na literatura (SILVA et al., 2013).

A maior diferença entre a reflectância das classes temáticas foi observada para NDII, NDVI, SR e VARI. Desta forma, através da análise de separabilidade, estes índices foram escolhidos por melhor se adequarem a classificação de imagens. Por conseguinte, obtiveram-se os intervalos de classe dos índices pela análise dos percentis 25 e 75, estes percentis foram utilizados visando à eliminação *outliers*.

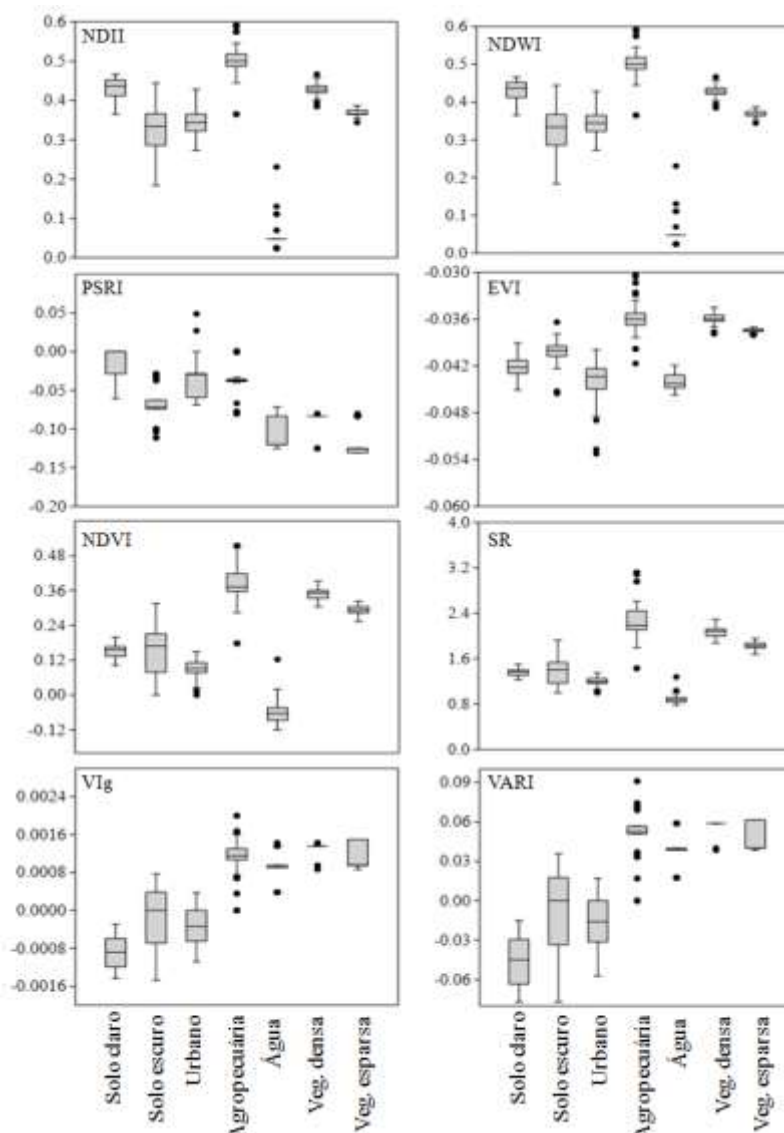


Figura 2. Distribuições das respostas dos índices de vegetação com base na análise de pixels puros dos principais tipos de cobertura do solo. Cada *boxplot* apresenta as parcelas de localização dos percentis 10, 25, 50, 75, e 90 e os círculos representam *outliers*.

A Figura 3 demonstra o resultado das classificações. Através da imagem é possível fazer uma comparação visual com a classificação realizada por MAXVER. Por meio da comparação é possível perceber que de forma geral, as imagens se assemelham, no entanto a vegetação é extrapolada na maioria dos índices, a vegetação do índice VARI é a que mais se assemelha a vegetação definida por MAXVER.

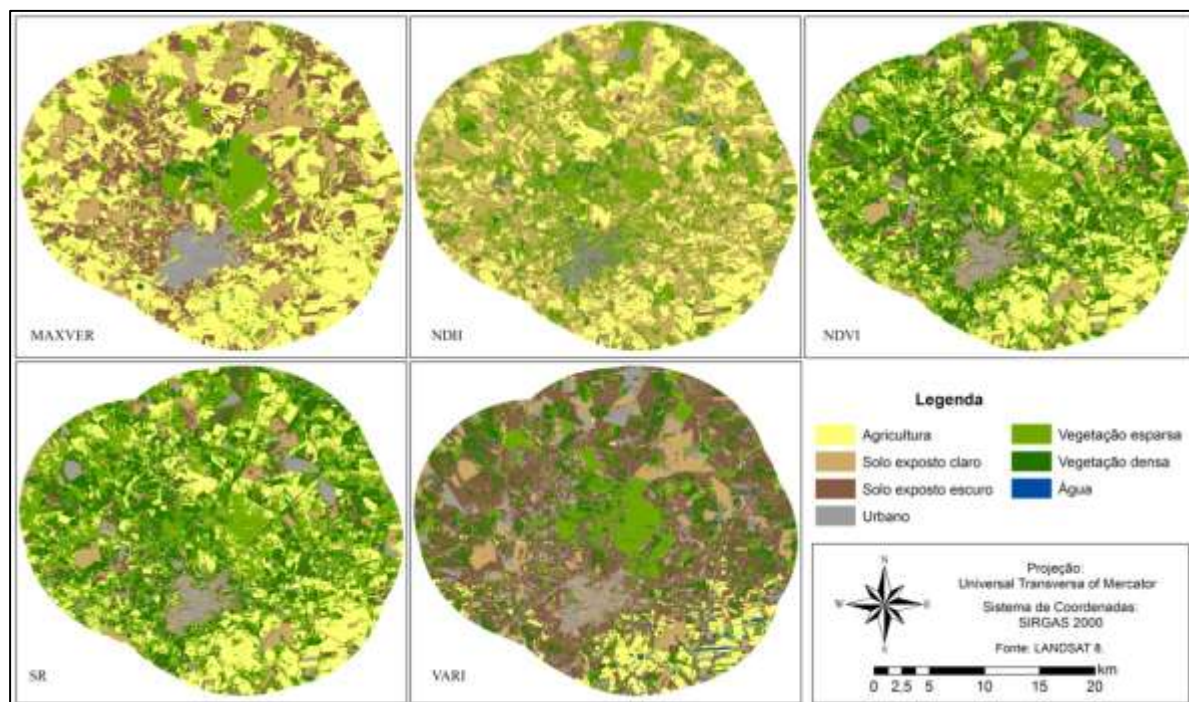


Figura 3. Classificações obtidas por meio do classificador MAXVER e dos índices de vegetação NDII, NDVI, SR e VARI.

Comparando os valores obtidos com o grau de concordância descritos por Landis e Koch (1977), observa-se que os resultados para o índice Kappa foram, em sua grande maioria, de concordância moderada (VARI – 0,46; NDVI – 0,55 e NDII - 0,52), destacando-se o índice SR (0,62) com boa concordância e o MAXVER (0,95) com concordância muito boa.

Barati et al. (2011) também encontraram alta precisão do índice SR para avaliação de fragmentos vegetais demonstrando um coeficiente de correlação de 0.765, o autor também avaliou os índices NDVI e NDII, encontrando coeficientes de correlação de 0.719 e 0.503, respectivamente. Souza et al. (2009) encontraram valores de Coeficiente de correlação de Pearson de 0,92 para o índice SR, 0,78 para NDII, 0,87 para NDVI e 0,92 para VARI.

Quando comparada a classificação realizada pelos índices, a superioridade da classificação por MAXVER esta relacionada ao fato de a classificação levar em consideração, além de seu valor numérico, o contexto de inserção do pixel. Possíveis problemas de separação entre as classes temáticas dos índices de vegetação podem ter resultado em classificações com baixo nível de exatidão, podendo ser explicado pela semelhança espectral existente entre os alvos, pequena variação entre os valores numéricos dos pixels, existência de sobreposição entre classes e pela baixa resolução espacial dos sensores.

O teste Qui-Quadrado (Tabela 1) revelou associação significativa entre a matriz de cada um dos índices e a matriz de MAXVER. Desta forma, pode-se inferir que o teste de McNemar rejeitou a hipótese de que as duas amostras das matrizes de erro eram independentes.

Tabela 1. Coeficiente de McNemar para os índices de vegetação e MAXVER.

	NDII		NDVI		SR		VARI	
MAXVER	χ^2	<i>p-value</i>	χ^2	<i>p-value</i>	χ^2	<i>p-value</i>	χ^2	<i>p-value</i>
	56,02	<0,0001	52,02	<0,0001	35,02	<0,0001	64,02	<0,0001

4. Conclusões

De forma geral, os índices de vegetação por pigmentos de folhas se mostraram mais eficientes do que os índices de vegetação por conteúdo de água nas folhas, no qual o SR foi o

índice de vegetação mais eficiente para classificação de imagens do Landsat8, apresentando índice Kappa de 0,62, considerado de boa concordância.

Embora o índice Kappa tenha apontado o índice SR como o de melhor qualidade na classificação, não houve diferença estatística entre os valores de Kappa gerados, a inexistência de um número adequado de repetições não permite conclusões sobre a eficiência dos índices de vegetação utilizados no processo de classificação de imagens Landsat8.

A inserção de mais pontos de análise de “*pixel* puro” poderia aperfeiçoar os intervalos definidos para cada classe temática. Além disso, é recomendado que os índices sejam aplicados em outras localidades, buscando avaliar de forma mais precisa as separações dos *ranges* de cada classe temática.

Agradecimentos

Os autores agradecem a Agência Nacional de Águas (ANA) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), processo nº 23038.003963/2016-17, pelo aporte financeiro a pesquisa.

Referências bibliográficas

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2014.

ANDRÉASSIAN, V. Waters and forests: from historical controversy to scientific debate. **Journal of Hydrology**, v. 291, p. 1–27, 2004.

ASKINS, R. A.; PHILBRICK, M. J. Effect of changes in regional forest abundance on the decline and recovery of a forest bird community. **Wilson Bulletin**, v. 99, n. 1, p. 7–21, 1987.

BANNARI, A. et al. A review of vegetation indices. **Remote Sensing Reviews**, v. 13, p. 95–120, 1995.

BARATI, S. et al. Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas. **The Egyptian Journal of Remote Sensing and Space Sciences**, v. 14, p. 49–56, 2011.

BONAN, G. B. Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. **SCIENCE**, v. 320, p. 1444–1449, 2008.

BROWN, A. E. et al. A review of paired catchment studies for determining changes in water yield resulting from alterations in vegetation. **Journal of Hydrology**, v. 310, p. 28–61, 2005.

CERQUEIRA, J. A. C.; ALVES, A. D. O. **Classificação de imagens de alta resolução espacial para o mapeamento do tipo de pavimento urbano**. III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. Anais...Recife: 2010Disponível em: <https://www.ufpe.br/cgtg/SIMGEOIII/IIISIMGEO_CD/artigos/FotoeSR/SR_e_PDI/A_26.pdf>

COSTA, M. H.; BOTTA, A.; CARDILLE, J. A. Effects of large-scale changes in land cover on the discharge of the Tocantins River, Southeastern Amazonia. **Journal of Hydrology**, v. 283, p. 206–217, 2003.

FEYISA, G. L. et al. Automated Water Extraction Index: A New Technique for Surface Water Mapping Using Landsat Imagery. **Remote Sensing of Environment journal**, v. 140, p. 23–35, 2014.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996.

GITELSON, A. A. et al. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 2002.

HE, F.; HUBBELL, S. P. Species-area relationships always overestimate extinction rates from habitat loss. **NATURE**, v. 473, p. 368–371, 2011.

HEROLD, M. et al. **THE SPECTRAL DIMENSION IN URBAN LAND COVER MAPPING FROM HIGH- RESOLUTION OPTICAL REMOTE SENSING DATA**. 3rd Symposium on Remote Sensing of Urban Areas. **Anais...**Istanbul: 2002Disponível em: <http://www.geogr.uni-jena.de/~c5hema/pub/istanb_herold_gardn_hadl_roberts.pdf>

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195–213, 2002.

HUNT JR, E. R.; ROCK, B. N. Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. **Remote Sensing of Environment**, v. 30, n. 1, p. 43–54, 1989.

ICMBIO. **Plano de manejo da Estação ecológica de Assis**Brasília, 2010.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, v. 33, n. 3, p. 159–179, 1977.

LEEuw, J. DE et al. Comparing accuracy assessments to infer superiority of image classification methods. **International Journal of Remote Sensing**, v. 27, n. 1, p. 223–232, 2006.

LU, D.; WENG, Q. Spectral Mixture Analysis of the Urban Landscape in Indianapolis with Landsat ETM + Imagery. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 9, p. 1053–1062, 2004.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, n. 5, p. 823–870, 2007.

LUGO, A. E.; PARROTTA, J. A.; BROWN, S. Caused by Tropical in Species Loss Recovery Their and Deforestation Through Management. **AMBIO**, v. 22, n. 2, p. 106–109, 1993.

MERZLYAK, M. N. et al. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia Plantarum**, v. 106, n. 1, p. 135–141, 1999.

MILLAR, C. I.; STEPHENSON, N. L.; STEPHENS, S. L. CLIMATE CHANGE AND FORESTS OF THE FUTURE : MANAGING IN THE FACE OF UNCERTAINTY. **Ecological Applications**, v. 17, n. 8, p. 2145–2151, 2007.

OLSON, S. H. et al. Deforestation and Malaria in Mâncio Lima County , Brazil. **Emerging Infectious Diseases**, v. 16, n. 7, p. 1108–1115, 2010.

ROUSE JR, J. W. et al. **Monitoring Vegetation Systems in the Great Plains with Erts**. Earth Resources Technology Satellite-1 Symposium. **Anais...**United States: NASA, 1973

SIEGEL, S.; CASTELLAN, N. **Nonparametric Statistics for the Behavioral Sciences**. New York: McGraw-Hill, 1988.

SILVA, E. B. DA et al. **Mapeamento de mudança de uso e cobertura da terra no bioma Cerrado entre 1975 e 2010 a partir da classificação de imagens Landsat Elaine**. XVI Simpósio Brasileiro de Sensoriamento Remoto. **Anais...**Foz do Iguaçu: INPE, 2013Disponível em: <<http://www.dsr.inpe.br/sbsr2013/files/p0236.pdf>>

SOUZA, A. A. DE; GALVÃO, L. S.; SANTOS, J. R. DOS. **Índices de vegetação derivados do sensor Hyperion/EO-1 para estimativa de parâmetros biofísicos de fitofisionomias de Cerrado**. XIV Simpósio Brasileiro de Sensoriamento Remoto. **Anais...**Natal: INPE, 2009Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.14.17.29/doc/3095-3102.pdf>>

WULDER, M. A.; FRNKLIN, S. E. **Remote sensing of forest environments: concepts and case studies**. 1. ed. New York: Springer Science+Business Media, 2003.

YASUOKA, J.; LEVINS, R. IMPACT OF DEFORESTATION AND AGRICULTURAL DEVELOPMENT ON ANOPHELINE ECOLOGY AND MALARIA EPIDEMIOLOGY. **American Society of Tropical Medicine and Hygiene IMPACT**, v. 76, n. 3, p. 450–460, 2007.