



CLASSIFICAÇÃO DE IMAGENS DO PANTANAL USANDO REDES NEURAIS ARTIFICIAIS MLP E PERCEPTRON LINEAR

Renan Rocha Fucci

renanfucci@hotmail.com

UFMS - Universidade Federal do Mato Grosso do Sul, Campus do Pantanal

Avenida Rio Branco, nº 1270, 79304-020, Mato Grosso do Sul, Corumbá, Brasil

Carlos Roberto Padovani

carlos.padovani@embrapa.br

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária

Rua 21 de Setembro, nº 1880, 79320-900, Mato Grosso do Sul, Corumbá, Brasil

Alex F. de Araujo

fa.alex@gmail.com

UFMS - Universidade Federal do Mato Grosso do Sul, Campus do Pantanal

Avenida Rio Branco, nº 1270, 79304-020, Mato Grosso do Sul, Corumbá, Brasil

Gustavo Manzon Nunes

gustavomn@gmail.com

UFMT - Universidade Federal do Mato Grosso

Av. Fernando Corrêa da Costa, nº 2367, 78060-900, Mato Grosso, Cuiabá, Brasil

Abstract. *A região do Pantanal é uma imensa planície inundável, de superfície dinâmica, mutável em suas dimensões espacial e temporal. Essa dinâmica está relacionada a processos biofísicos e mais recentemente por ações humanas, ocasionando alta variabilidade espacial e temporal da cobertura vegetal. Em virtude de sua dimensão e dificuldade de acesso, o Pantanal carece de tecnologias que possam auxiliar em análises e estudos para a sua conservação e manejo, de maneira automatizada. Neste trabalho, apresentam-se os resultados da aplicação de classificadores de imagens baseados em Redes Neurais Artificiais (RNA), para imagens do Pantanal, produzidas pelo satélite Rapideye. O objetivo foi rotular os pixels da imagem de entrada, agrupando-os em classes que representam as diferentes áreas de vegetação e água. Os resultados preliminares produzidos neste trabalho foram bastante promissores, demonstrando que a metodologia adotada é pertinente e as técnicas de classificação implementadas, podem contribuir significativamente com a tarefa de análise e interpretação de imagens de satélite do Pantanal.*

Keywords: *Redes Neurais Artificiais (RNA), Classificadores, Sensoriamento Remoto, Reconhecimento de Padrões.*

1 INTRODUÇÃO

Situada no centro-oeste brasileiro, a Bacia do Alto rio Paraguai (BAP) compreende a região do Pantanal, uma das maiores planícies alagáveis do mundo, oriundo da confluência de diversos rios, com características favoráveis às inundações devido a sua estrutura física de relevo e ao clima tropical (SOUZA et al., 2006). As áreas inundáveis são importantes para a pesca no Pantanal, pois são nessas áreas, que ocorre a vegetação aquática, habitat e áreas de criadouro de diversos organismos aquáticos, entre eles diversas espécies de peixes de valor comercial do Pantanal (Padovani et al., 2002). O mapeamento dessas áreas é um meio de avaliar a disponibilidade de ambientes disponíveis para os peixes e que favorecem a pesca esportiva e profissional. O mapeamento das áreas inundáveis e vegetação aquática tem se mostrado um desafio com as técnicas disponíveis de classificação de imagens de satélite e novas técnicas devem ser exploradas para melhorar os mapeamentos. Nesse contexto, este trabalho teve como objetivo avaliar a viabilidade da classificação de imagens do sensor Rapideye, baseada em Redes Neurais Artificiais para uma área de relevância para a pesca, a região do rio Paraguai no município de Corumbá, Pantanal sul. Para alcançar esse objetivo fez-se um levantamento bibliográfico aprofundado sobre os principais algoritmos computacionais aplicados na classificação de imagens de satélite, bem como aqueles com características mais promissoras, considerando os atributos das imagens do Pantanal brasileiro. Esse levantamento nos permitiu verificar que as Redes Neurais Artificiais (RNA), são ferramentas aplicadas para resolver vários problemas de classificação de imagens, entre elas, as imagens de sensoriamento remoto (SHWETHA & KUMAR, 2015; CRACKNELL & READING, 2015; JAYANTH et al., 2015). Assim, a RNA *Perceptron* e *Perceptron* Multicamadas foram estudadas, implementadas e testadas para identificar as vantagens de cada uma e qual é mais promissora para classificação de imagens do Pantanal.

O restante deste artigo está organizado da seguinte forma: na seção 2 apresenta-se o levantamento bibliográfico relacionado ao tema abordado. Na seção 3 detalha-se a metodologia adotada. Na seção 4 apresenta-se a análise dos resultados produzidos neste trabalho e, por fim, na seção 5 tem-se a conclusão e considerações finais deste artigo.

2 ESTADO DA ARTE

Sensoriamento remoto, de acordo com o WENG (2010), refere-se às atividades de gravação, observação, e percepção (sensoriamento) de objetos ou eventos em áreas a longa distância. De outro ponto de vista, com base na definição de CAMPBELL & WYNNE (2011), sensoriamento remoto pode ser interpretado como uma abstração e sintetização de informação de uma superfície terrestre, adquirida por meio de perspectivas aéreas utilizando radiação eletromagnética, isto é, por intermédio de imagens de satélite. Desta forma, para compreender essas imagens, foram criados sistemas que auxiliam aos usuários a visualizar e interpretar as tarefas de gravação, observação e percepção, através da virtualização e compilação dessas informações. Esses sistemas são conhecidos como *Geographic Information System* (GIS).

Deste modo, essas informações obtidas pelos Sensores Remotos podem ser interpretadas em programas e aplicações computacionais, capazes de manipular dados e características de imagens digitais. Este conceito é denominado Processamento de Imagens Digitais, e envolve diversas técnicas computacionais que podem contribuir com os profissionais da área de Sensoriamento Remoto na realização de suas tarefas. As técnicas de processamentos de imagens podem ser combinadas em aplicações que auxiliem na análise, classificação e manipulação de dados, para que possam ser produzidas imagens e estatísticas equivalentes a esses dados.

Para representar e parametrizar as características das imagens capturadas por Sensores Remotos, a partir de estudos, foi exposto alguns padrões de referências denominados Índices Radiométricos. Esses índices, também conhecidos como descritores, são escalas medidas capazes de determinar tipos de informações, tais como edifícios, áreas vegetativas, áreas aquáticas, dentre outros (FRANÇA, TAVARES, MOREIRA, 2012). Os índices radiométricos pertinentes ao objetivo e utilizados neste trabalho são: o NDVI (*Normalized Difference Vegetation Index*) específico para vegetação; o NDWI (*Normalized Difference Water Index*) característico para água; e o EVI (*Enhanced Vegetation Index*) exclusivo para vegetação, com uma maior sensibilidade em áreas fortemente vegetada (FERREIRA et al., 2008). A banda espectral NIR (*Near-infrared*) também foi utilizada como um dos descritores, pois possui base teórica na literatura que indica sua utilização para auxiliar na diferenciação entre água e vegetação (SCHNEIDER & MCGINNIS, 1982).

Segundo LILLESAND & KIEFER (2007), os principais e mais generalizados exemplos destas aplicações são: contagem de objetos (ANDRADE, 2011); classificação de áreas relevantes e vigilância e previsão de eventos biofísicos (SHWETHA & KUMAR, 2015). Os problemas de classificação, por exemplo, envolvem a tarefa de atribuir a um padrão desconhecido, uma entre várias classes conhecidas (BRAGA et al., 2012). No contexto de processamento de imagens de sensores remotos, classificação pode ser retratada como o processo de designação de classes para um conjunto de pixels de diversas bandas espectrais (CAMPBELL & WYNNE, 2011).

O reconhecimento e classificação de padrões aplicados em imagens digitais, utilizando as estruturas de treinamento supervisionado de Redes Neurais Artificiais, têm como base as características estruturais de um neurônio biológico e as ciências cognitivas (BRAGA et al., 2012).

A sequência de passos para o processamento e classificação de imagens de sistemas GIS, conforme (WENG, 2010), é composta pela interpretação de imagens e a criação de mapas ou conjunto de mapas, com suas respectivas características e conjunto de dados, a digitalização e compilação dessas informações a utilização de métodos para análise e classificação dessas informações e p a construção de imagens processadas, categorizadas e/ou classificadas em seus respectivos conjuntos e mapas. Com base na obra de (BRAGA et al., 2012), algumas outras aplicações para a classificação de imagens são: reconhecimento de caracteres e imagens (KAMBLE & HEGADI, 2015; VO, TRAN, MA, 2015), auxílio a diagnósticos médicos (ARAUJO, CONSTANTINOU, TAVARES, 2014; MA et al., 2010), análise de risco

de crédito (KOUTANAEL, SAJEDI, KHANBABAEI, 2015), detecção de fraude (VLASSELAER, 2015), entre outros.

Sob a perspectiva de RICHERT & COELHO (2013), o processo no qual se coloca um aprendizado de máquina para aprender como desenvolver uma tarefa a partir de exemplos, e ao final distingui-las, é denominado de classificadores supervisionados ou treinamentos supervisionados. No contexto da classificação de imagens, os métodos baseados em aprendizados de máquina que mais são utilizados são: *Artificial Neural Network* (ANN) e *Support Vector Machines* (SVM), respectivamente interpretados em português por Redes Neurais Artificiais (RNA) e Máquinas de Vetores de Suporte (LEE et al., 2009; DU & WANG, 2015). Nas ações exclusivas de classificação de imagens aplicadas a sensores remotos, os grupos mais usuais relacionadas à RNA são os algoritmos supervisionados *Linear Perceptron* e MLP – *Multi-Layer Perceptron* (MAHMOM & YA'ACOB, 2014; ELAALEM, 2013; ANDRADE, 2011). Em seu trabalho sobre classificação de imagens, PISANI, et al. (2009), apresentaram a comparação dos resultados e ponderações sobre os aspectos da utilização desses e outros algoritmos quando aplicados a imagens de satélite das bacias hidrográficas na região do Rio das Pedras, Itatinga-SP.

3 METODOLOGIA DE CLASSIFICAÇÃO ADOTADA

A partir do levantamento bibliográfico, os algoritmos *Perceptron* Linear e o *Perceptron* Múltiplas Camadas (MLP – *Multi-layer Perceptron*) foram escolhidos como consequência de sua constante e positiva referência em diversas publicações, como em HOREWICZ, 2008; ALBUQUERQUE et al., 2009; KUSAKUNNIRAN, 2012; BRAGA et al., 2012. O desenvolvimento dos algoritmos de RNA deste trabalho trouxeram como seu principal alicerce teórico o trabalho de BRAGA et al. (2012). Desta forma, as RNAs, utilizando estritamente os algoritmos *Perceptron* e MLP, foram implementadas na linguagem de programação orientada a objeto Java (ORACLA, 2014), com o auxílio da biblioteca *Neuroph* (SEVARAC, 2011), específica para Redes Neurais Artificiais e *Open Source* (CC, 2013).

Como primeiro passo da metodologia adotada, criou-se um vetor de descritores baseados nos índices radiométricos. A escolha de amostras foi feita por um especialista em sensoriamento remoto com ênfase em geoprocessamento aplicado ao Pantanal, usando as cinco bandas espectrais do sensor *RapidEye* (*Red*, *Green*, *Blue*, *RedEdge* e *Nir*). As imagens classificadas estão no formato TIF com profundidade de cor de 16 bits. As imagens de amostra contêm unidades dos dois padrões definidos das classes de classificação desejada (água e vegetação).

Para a composição do vetor de descritores, a partir dos cálculos de base de composição dos índices NDVI, EVI, NDWI e NIR, criou-se uma matriz para armazenar cada índice usado como descritor, com as mesmas dimensões das imagens das bandas espectrais, todavia, com todos os valores de pixels nulos. Após a criação desta imagem, para cada coordenada de pixel, calcularam-se os índices correspondentes, utilizando as mesmas coordenadas de pixels das imagens das bandas do sensor remoto. Como alguns dos índices possuem escalas predefinidas

referentes aos limites dos índices, foram estabelecidos cálculos para a representação dos pixels das imagens das bandas espectrais de 16bits para com as escalas dos índices.




Figura 1. Diagrama de Fluxo do Perceptron Linear

Na Figura 1, o item A representa o início do algoritmo, o B é o passo de treinamento, que é a apresentação das imagens de amostra para o algoritmo. O item C é o passo da classificação pixel a pixel da imagem original após a criação do vetor de pesos do treinamento da rede (Item B), o item D expressa o passo de composição da classificação, e por fim, o item E expõe o fim do classificado com o Perceptron Linear.

É bom recapitular que essa sequência de passos com o Perceptron Linear, do item A até E, são executados duas vezes, uma para classificação de água e não água e a outra para a classificação de vegetação e não vegetação. Neste caso, o solo não é um passo de

classificação utilizando uma RNA, e sim uma por uma lógica de resto, ou seja, como já foram classificados água e vegetação, o que sobrou e não foi classificado em nenhum caso, é considerado como solo.




Figura 2. Diagrama de Fluxo do Perceptron de Múltiplas Camadas

A Figura 2 demonstra a sequência do classificador utilizando a RNA Perceptron de Múltiplas Camadas, no qual o item A é o início do algoritmo, o item B o passo de treinamento do algoritmo, etapa que são apresentadas as imagens de amostra para a rede do MLP. O item C manifesta a classificação a cada pixel da imagem original, em seguida ao treinamento (item B), o D a composição da imagem classificada no item C, e por último, o item E manifesta o fim do classificador MLP.

Baseando-se nos conceitos de treinamento de uma RNA, os treinamentos devem possuir a sua quantidade proporcional de amostra para cada classe desejada, ou seja, a mesma porção de pixel de água e de vegetação, além do mais, para seguir os protocolos de RNA (BRAGA et al., 2012, Pág. 31), o treinamento da rede foi feito de modo interpolado, na apresentação de amostras das classes para o treinamento da rede, foi intercalada uma amostra de água, uma de vegetação e uma de solo até o término das amostras. Nos treinamentos da RNA-MLP, empregou-se exclusivamente a arquitetura *BackPropagation*, pois, na fase *forward*, define-se a saída da rede para o padrão de entrada, na fase *backward* atualiza a arquitetura supervisionada para atualizar os pesos, além de aplicar a regra delta no erro da rede (BRAGA et al., 2012, Pág. 74-84). Para ambos os algoritmos, estipulou-se taxa de erro igual a zero e limite de iteração igual a um trilhão, a fim de tentar forçar o algoritmo, na atualização dos pesos na etapa de treinamento, a ter a menor taxa de erro possível.

Na etapa de classificação, foram adotados os mesmos parâmetros adotados para o treinamento, juntamente com os pesos obtidos por aquela etapa. A imagem classificada também está no formato TIF com profundidade de cor de 16bits. Nesta etapa, cria-se uma imagem de saída com as mesmas dimensões da imagem original, porém com todos os valores dos pixels nulos. Em seguida, os algoritmos leem cada pixel da imagem original, calculam os seus descritores e enviam para a RNA. O classificador processa esse pixel retornando um valor representando uma das classes (água, vegetação ou solo), esse valor é transformado em uma cor predefinida como azul para água, verde para vegetação e vermelho para áreas de solo. Essa cor é mapeada na imagem de saída, na sua respectiva posição.

No Perceptron Linear, Figura-1, o algoritmo é executado duas vezes separando as classes desejadas uma por vez, primeiro separa o que é água do que não é água e vegetação do que não é vegetação. Para classificar o solo, visto que não se usou nenhum índice radiométrico específico para solo, não se utilizou nenhuma arquitetura das Redes Neurais Artificiais, a classificação foi feita com os pixels remanescentes que não foram classificados como vegetação ou água. Em contrapartida, no Perceptron de Múltiplas Camadas (MLP), o algoritmo é executado uma única vez separando as três classes desejadas.

Para definir a melhor solução ou identificar qual abordagem é mais apropriada, analisaram-se diferentes treinamentos. Estes foram realizados com diversas combinações de índices, com aplicação de diferentes funções de ativação, que, conforme (BRAGA et al., 2012, Pág. 9), podem ser quaisquer funções matemáticas escolhidas de acordo com o comportamento do erro do problema. Nestes treinamentos, a análise de precisão do classificador foi comparada com uma classificação feita manualmente por um especialista em sensoriamento remoto, a qual foi construída por este a partir da análise visual dos dados do satélite *Rapideye*, auxiliado por fotografias aéreas georreferenciadas da região em análise.




Figura 3. Imagem Original




Figura 4. Imagem Amostra




Figura 5. Imagem Parâmetro

A Figura 3 representa a imagem original e a ser classificada, adquirida pelo sensor remoto *Rapideye*, a Figura 4 é a imagem de amostras, adotada no treinamento do Perceptron Linear e do MLP (Figura 1-B e 2-B respectivamente) marcadas manualmente pelo especialista, na qual os pixels em azul representam regiões com água, em verde vegetação e em vermelho solo, e a Figura 5 é a imagem de parâmetro, utilizada na análises dos resultados de ambos os classificadores, após as classificações, também compostas à mão pelo especialista, nas quais as regiões em azul representam a água, em verde a vegetação e em vermelho o solo.

4 ANÁLISE DOS RESULTADOS

Os resultados foram analisados a partir da sequência de passos dos dois algoritmos (Figura 1 e 2), porém, a partir da composição dos descritores da imagem de amostra. Ambas as sequências de passos foram repetidas com diferentes combinações de índices Radiométricos. Ademais, para cada uma dessas combinações de descritores e execução dos passos, foram aplicados três diferentes funções de ativação, ou transferência, sendo elas: Sigmoide (*Sigmoid*), Rampa (*Ramp*) e Gaussiano (*Gaussian*) para o Perceptron Linear, Seno (*Sin*) e Hiperbólica (*Tanh*) para o Perceptron de Múltiplas Camadas.

No *Perceptron* Linear, as combinações de índices que produziram os melhores resultados para a classificação de água foi NDWI-EVI-NDVI-NIR e a para a classificação vegetação foi NDVI-EVI-NIR. Nesta classificação, as amostras de solo foram usadas para indicar que aquelas regiões não era água e nem solo. Entretanto, como não se adotou nenhum descritor de solo, como dito anteriormente, não foi produzida a classe solo para os pixels após a classificação utilizando uma Rede Neural Artificial.

Tabela 1. Porcentagem de Acerto do Perceptron Linear

Classificação com Perceptron Linear			
Vegetação (NDVI, EVI e NIR)		Água (NDVI, EVI, NDWI, NIR)	
Gaussiano	0,00%	Gaussiano	7,78%
Sigmoide	93,06%	Sigmoide	99,42%
Rampa	56,91%	Rampa	98,57%

Com o algoritmo do *Perceptron* de Múltiplas Camadas a combinação de índice mais adequada para a classificação foi NDVI, EVI, NDWI e NIR.

Tabela 2. Porcentagem de Acerto do Perceptron de Múltiplas Camadas

Classificação com Perceptron de Múltiplas Camadas			
Vegetação (NDVI, EVI, NDWI, NIR)		Água (NDVI, EVI, NDWI, NIR)	
TANH	96,19%	TANH	89,55%
SIN	85,30%	SIN	56,93%

Os melhores resultados, após todos os conjuntos de etapas para o algoritmo do Perceptron Linear, foram obtidos empregando a função de ativação Sigmoid, já no Perceptron de Múltiplas Camadas, foram obtidos utilizando a função de ativação Hiperbólica (TANH). Estas escolhas foram feitas com base no maior índice de acerto, comparando a porcentagem de acerto das classificações com a imagem parâmetro, Figura 5.




Figura 6 - Classificação com Perceptron Linear




Figura 7 - Classificação com Perceptron de Múltiplas Camadas

A Figura 6 é o resultado da classificação com o algoritmo Perceptron Linear e Figura 7 é o resultado da classificação com o algoritmo do Perceptron de Múltiplas Camadas. Como citado na metodologia deste artigo, o Perceptron Linear é executado duas vezes para a classificação, logo, a composição da Figura 6 é uma junção dos dois resultados do algoritmo. Em ambas as imagens, o que está em verde representa a vegetação, em azul a água, e em vermelho os pixels não classificados, ou classificados como solo devido às amostras de solo usadas. As imagens resultantes dos classificadores foram comparadas com a imagem de parâmetro (Figura 5) feita pelo especialista, no qual a imagem obtida pelo Perceptron Linear (Figura 6) teve 96,24% de acerto e a imagem obtida pelo Perceptron Múltiplas Camadas (Figura 7) obteve 92,87% de precisão.

5 CONCLUSÕES

A partir deste trabalho, verificou-se que as Redes Neurais Artificiais podem ser uma alternativa muito viável como classificador de imagens, todavia, podem ser um pouco instáveis com relação à resolução de problemas que não estejam bem modelados, tornando-a assim uma técnica que requer tempo e conhecimento a priori sobre o problema para permitir escolher e calcular os descritores corretamente. Apesar disso, os resultados preliminares foram promissores, permitindo obter aproximadamente 90% de acerto em ambas as propostas de classificadores.

Ao decorrer deste trabalho, descobriu-se também que antes de escolher o algoritmo, arquitetura, função de ativação e outros aspectos referentes à RNA, a análise de erros através de gráficos é uma boa prática e contribuiu para reduzir consideravelmente o tempo e esforço para desenvolvimento do algoritmo adequadamente. Outra possível alternativa para a resolução dos problemas desse gênero, muito presente na literatura atual de classificadores, e que será estudado e analisado num trabalho futuro, é utilizar outros classificadores, como o SVM. Como trabalhos futuros, é importante ressaltar que a classificação do solo será trabalhada.

REFERÊNCIAS

- ALBUQUERQUE, V. H. C. et al. Evaluation of Multilayer Perceptron and Self-Organizing Map Neural Network Topologies applied on Microstructure Segmentation from Metallographic Images. *NDT & E International*, ISSN: 0963-8695, Elsevier, Volume 42, Issue 7, pp. 644-651, October 2009, DOI: 10.1016/j.ndteint.2009.05.002
- ANDRADE, L. N. et al. Redes Neurais Artificiais(RNA) aplicadas à classificação de áreas cafeeiras na região de Três Pontas-MG. *Anais XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR*, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.7603.
- ARAUJO, A. F.; CONSTANTINOU, C. E.; TAVARES, M. R. S. New artificial life model for image enhancement. *Expert Systems with Applications*, DOI: 10.1016/j.eswa.2014.03.029, ISSN: 0957-4174, Elsevier, Volume 41, Issue 13, pp. 5892–5906, October 2014
- BRAGA, A. P.; CARVALHO, A. C. P. de L. F; LUDERMIR, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*, 2ª Edição. Rio de Janeiro, LTC, 2012.
- CAMPBELL, J. B ; WYNNE, R. H. *Introduction to Remote Sensing*, Fifth Edition. The Guilford Press, 2011.
- CC. Creative Commons, Open Source Initiative (OSI), The Open Source Definition (OSD). November 25, 2013. Available in: < <http://opensource.org/definition>>, Access in: August 30, 2015.
- CRACKNELL, M. J. & READING, A. M. Geological mapping using remote sensing data: A comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. *Computer and Geosciences*, Elsevier: 2015;
- DU, X. & WANG, J. J. Support image set machine: jointly learning representation and classifier for image ser classification. *Elsevier: Knowledge-Based Systems* 78 (2015) 51-58.
- ELAALEM, M. M. et al. Performance of Supervised Classification for Mapping Land Cover and Land Use in Jeffara Plain of Libya. *International Conference on Food and Agricultural Sciences*. V55: 7, (2013).
- FERREIRA, L. G.; FERREIRA, N. C.; FERREIRA, M.E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. *Acta Sci. Biol. Sci*, v. 30, n. 4, p. 379-390, 2008.
- FRANÇA, A. F.; TAVARES, J. R.; MOREIRA, J. C. C. Índices NDVI, NDWI e NDBI como ferramentas ao mapeamento temático do entorno da lagoa olho d’água, em Jaboatão dos Guararapes – PE. *Simpósio Brasileiro de Ciências Geodésicas e Tecnologia da Geoinformação*, Recife – PE, 2012.
- GIONGO, P. R.; PADOVANI, C. R.; VETORAZZI, C. A. Variabilidade espacial e temporal do albedo obtido a partir de imagens MODIS na região do Pantanal. *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*, Natal, Brasil, 25-30 abril 2009, INPE, p. 4715-4722.
- HOREWICZ, M. C. Reconhecimento de Modulação Digital de Sinais de Comunicações. *II Simpósio de aplicações operacionais em Áreas de Defesas (SIGE)* Maj Correa, Brasília-DF, 2008.

- JAYANTH, J.; KOLIWAD, S.; KUMAR, T. A. Classification of Remote Sensed data using Artificial Bee Colony algorithm. The Egyptian Journal of Remote Sensing and Space Science, Elsevier: 2015
- KAMBLE, P. M.; HEGADI, R. S. Handwritten Marathi character recognition using R-HOG Feature. International Conference on Advanced Computing Technologies and Applications (ICACTA), Elsevier, 2015.
- KOUTANAEI, F. N.; SAJEDI, H.; KHANBABAEI, M. A Hybrid data mining model of feature selection algorithm and ensemble learning classifiers for credit scoring. Journal of Retailing and Consumer Services, volume 27, Pages 11-23, November 2015.
- KUSAKUNNIRAN, W.; WU, Q.; ZHANG, J.; LI, H. Cross-view and multi-view gait recognitions based on view transformation model using multi-layer Perceptron. Pattern Recognition Letters, Volume 33, Issue 7, Page 882-889, May 2012.
- LEE, J. et al. Performance testing of several classifier for differentiating obstructive lungs diseases based on texture analysis at high-resolution computerized tomography (HRCT). Elsevier: Computer Methods and Programs in Biomedicine 93 (2009) 206-215.
- LILLESAND, T. M.; KIEFER, R. W. Remote Sensing and Image Interpretation, Sixth Edition. Hardcover, 2007.
- MA, Z.; TAVARES, M. R. S.; JORGE, R. N.; MASCARENHAS, T.; A Review of Algorithms for Medical Image Segmentation and their Applications to the female Pelvic Cavity. Computer Methods in Biomechanics and Biomedical Engineering, ISSN: 1025-5842 (print) - 1476-8259 (online), Taylor & Francis, DOI: 10.1080/10255840903131878, Volume 13, Issue 2, pp. 235-246, April 2010
- MAHMOM, N. A. & YA'ACOB, N. A Review on Classification of Satellite Image Using Artificial Neural Network (ANN). IEEE 5th Control and System Graduate Research Colloquium, Aug, 11-12, UiTM, Shah Alam, Malaysia (2014).
- ORACLE. Legal Notices: Privacy, Terms of Use, Copyright, Trademarks, Logos. January 15, 2014. Available in: <<http://www.oracle.com/us/legal/terms/index.html>>, Access in: August 30, 2015.
- PADOVANI, C.R.; MORAES, A. S. e RESENDE, E. K. Banco de dados geográfico da Estrada Parque-Pantanal, MS: enfoque na atividade de pesca esportiva. Corumbá: Embrapa Pantanal, 2003. 26p.
- PAPA, J. F. & FALCÃO, A. X. Optimum-Path Forest: A Novel and Powerful Framework for Supervised Graph-Based Pattern Recognition Techniques. Campinas: Unicamp, 2008. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/ctd/2009/006.pdf>>, acesso em: 09 de Julho de 2015.
- PISANI, R. J. et al. Land Use Classification Using Optimum-Path Forest. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 7063-7070.
- RICHERT, W. & COELHO, L. P. Building Machine Learning Systems with Python, First Edition. PacktPub, 2013.
- SCHNEIDER, S. R., & MCGINNIS, D. F., JR., 1982, The NOAA AVHRR: A new sensor for monitoring crop growth. Proceedings of Machine Processing of Remotely Sensed Data Symposium, LARS, West Lafayette, Indiana, p. 281002E.

SEVARAC, Z. Neural Networks on the NetBeans Platform. February 2011. Available in: <<http://www.oracle.com/technetwork/articles/java/nbneural-317387.html>>, Access in: August 20, 2015.

SHWETHA, H. R. & KUMAR, D. N. Prediction of Land Surface Temperature under Cloudy Conditions using Microwave Remote Sensing and ANN. International Conference on Water Resources, Coastal and Ocean Engineering (ICWRCOE 2015), Elsevier: 2015.

SOUZA, C. A.; LANI, J. L.; SOUZA, J. B. Origem e Evolução do Pantanal Mato-Grossense. Simpósio Nacional de Geomorfologia / Regional Conference on Geomorphology, 2006.

VLASSELAER, V. V. et al.; A novel approach for automated credit card Transaction fraud detection using network-based extensions. Decision Support Systems, Volume 75, Page 38-48, July 2015.

VO, T.; TRAN, D.; MA, A.; Tensor decomposition and application in image classification with histogram of oriented gradients. Neurocomputing, Elsevier, 2015.

WENG, Qihao. Remote Sensing and GIS Interaction: Theories, Methods, and Applications, First Edition. The McGraw-Hill Companies, 2010.