

Avaliação da classificação não-supervisionada em imagens de alta resolução, utilizando a lógica fuzzy.

Eduardo Lima de Andrade¹

Ullisses Marcelo da Silva²

¹Instituto Federal de Educação, Ciência e Tecnologia de Goiás.
Rua 75, Nº. 46, Centro – 74055-110 – Goiânia/GO.
eduardoandrade77@gmail.com

²Instituto Federal de Educação, Ciência e Tecnologia de Goiás.
Rua 75, Nº. 46, Centro – 74055-110 – Goiânia/GO.
ullisses@bb.com.br

Abstract. In any classification process of satellite images, modeling data is a complex one, due it's programming features and images nuances, then requiring more advanced methods of classification that best fit user's requirements. Fuzzy logic, or diffuse logic or even Fuzzy sets gives the roots for the generation of strong techniques for solutioning problems, it got a wide applicability, specially in control and decisions areas. Fuzzy logic's potency consists on it's ability to deduce conclusions and to generate answers based on vague, ambiguous and incomplete/inaccurate information. In this respect, Fuzzy is root system got the skill to ratiocinate in a similar way as the humans. In this service, there'll be applied unsupervised techniques of classification of images in high definition of the satellite Quick-Bird, using a extension to the software ENVI, based on Fuzzy logic, named as Fuzzy K-Means. To observe the result's quality and accuracy of it's information using Fuzzy Logic, there was used a different classification process. Using a different classification process, you can see that fuzzy is quality depends on the adoption of several rules that are appropriate to a decent molding of sets that are relevant to the variable that you choose to classify the image.

Palavras Chave: sensoriamento remoto, processamento digital de imagens, classificação de imagens, mínima distância, fuzzy, remote sensing, processing digital image, image classification, minimum distance, Quickbird.

1. Introdução

As imagens digitais geradas pelos sensores remotos de alta resolução (Quick-Bird), abrangem muito mais detalhes, do que sensores anteriormente existentes (Landsat), sendo possível visualizar os elementos componentes de uma cena urbana como: árvores, edificações, estradas, dentre outros (Kuo et al., 2001).

Devido a grande distinção entre elementos da cena, as imagens de alta resolução têm vasta aplicação entre usuários e sistemas que buscam obter informações precisas em estudos de mapeamento e monitoramento principalmente.

Mas quantificar e qualificar os elementos presentes na imagem pode ser facilmente realizado por humanos, que possuem grande capacidade de distinguir abstrações, tendo como base diversos aspectos, como prévio conhecimento, análise visual, etc.

Porém em processos computacionais de classificação, essa modelagem dos dados torna-se um processo complexo devido às características de programação e nuances que uma imagem apresenta, exigindo assim, métodos de classificação mais elaborados que atendem melhor as exigências dos usuários.

Os métodos de classificação tradicionais, tais como a máxima verossimilhança que utilizam apenas as características espectrais são incapazes de diferenciar de forma acurada classes que possuem semelhança espectral tais como: grama/árvore e estradas/edificações, sendo necessária a implementação de novos métodos que visem classificar de forma mais

acurada as imagens de alta resolução. (Shackelford e Davis, 2002).

A teoria Fuzzy também chamada teoria nebulosa tem se destacado cada vez mais na área de processamento de imagens, pois proporciona uma ferramenta satisfatória na representação de incertezas que surgem em segmentação ou classificação, sendo possível através dela modelar a atividade de percepção dos seres humanos. Através da teoria nebulosa as incertezas podem ser propagadas ao próximo nível lógico e mais alto de um determinado sistema que retém a informação, em vez de ser forçado a chegar prematuramente a uma decisão que é obrigatória em um processo convencional (Cheng et al., 2001).

A Lógica Fuzzy, Difusa ou Lógica Nebulosa, também pode ser definida, como a lógica que suporta os modos de raciocínio que são aproximados, ao invés de exatos, como estamos naturalmente acostumados a trabalhar, sendo por isso apontada como uma valiosa ferramenta alternativa aos classificadores tradicionais.

As regras nebulosas ou Fuzzy permitem atribuir rótulos como: pouco, razoável, muito, a cada conjunto, que variam de 0 a 1, combinando assim as funções de pertinência obtendo índices pertinentes a cada classe. Através dessas análises é possível atribuir uma modelagem de classes para a obtenção de resultados satisfatórios.

2. Metodologia de Trabalho

O objetivo da classificação de imagens em sensoriamento remoto é identificar as feições da imagem, isto é, traduzir os diversos padrões de energia eletromagnética refletida em classes de cobertura terrestre (Lillesand e Kiefer, 1994).

A metodologia do estudo se baseia na classificação não-supervisionada de imagens, tendo o objetivo de avaliar e discutir a acurácia e os resultados na aplicabilidade da Lógica Fuzzy, comparado ao processo não automático de classificação.

Para observar a qualidade dos resultados e a acurácia das informações utilizando a Lógica Fuzzy, foram utilizados processos de classificação diferentes, onde em um primeiro momento utilizou-se uma ferramenta tradicional de classificação supervisionada denominada *Minimum Distance* (distância mínima), já implantada no software ENVI da *Research Systems INC* e posteriormente o método de classificação não-supervisionada utilizando o algoritmo *Fuzzy K-means*, extensão para o ENVI desenvolvida por Mort Canty. A imagem utilizada é de um recorte da cena do município de Anápolis do sensor Quickbird, desenvolvido pela Digitalglobe, coletando dados com 61 centímetros de resolução espacial no pancromático e 2,5 metros no multiespectral, com composição colorida RGB das bandas 1,2 e 3.

A classificação supervisionada é o procedimento utilizado com maior frequência para análise quantitativa de dados de imagens de Sensoriamento Remoto. Neste processo são utilizados algoritmos para nomear os *pixels* em uma imagem de forma a representar tipos específicos de cobertura terrestre ou classes que são conhecidas a priori (Richards e Jia, 1994). A figura 1 mostra a representação do processo de classificação supervisionada. Os passos a serem seguidos na classificação supervisionada consistem em: decidir os conjuntos de classes na imagem; escolher *pixels* que representem cada classe desejada, denominados de amostras; definir os parâmetros para o algoritmo, que serão as propriedades que definirão as separações espectrais; produzir o mapa temático e tabelas que resumem a classificação. A seleção das amostras é essencial e imprescindível para o resultado da classificação.



Figura 1 – Representação do processo de classificação supervisionada

A classificação por Fuzzy, por sua vez, utiliza-se de um algoritmo para determinar o número e a localização das classes espectrais. O operador identifica essas classes a posteriori, analisando as assinaturas para determinar o que cada classe é/ou representa (Figura 2), podendo ser necessária a verificação através de dados de referência disponíveis que podem incluir mapas e visitas. (Schowengerdt, 1983.)

O algoritmo Fuzzy K-means utilizado no processo, que foi desenvolvido por Mort Canty, consiste de uma iteração simples de equações. O algoritmo termina quando a matriz de elementos da classificação, que é gerada a partir da imagem multi-espectral, deixa de apresentar mudanças significativas.

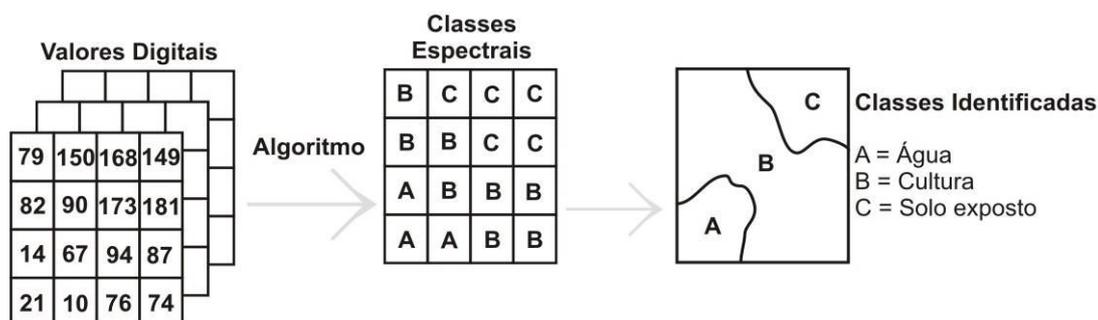


Figura 2 – Representação do processo de classificação não-supervisionada

O sistema Fuzzy possui etapas que são executadas pelo algoritmo, que são elas a fuzzificação, a inferência de regras e a defuzzificação.

A figura 3 representa o processo Fuzzy onde a fuzzificação é a entrada de valores da matriz de imagem, já a etapa de inferência e regras constitui uma das etapas mais importantes, são expressas as proposições, sendo de fundamental importância para o desempenho de todo o sistema. A última etapa é a defuzzificação que consiste em obter a melhor representação para o conjunto de saída Fuzzy, onde o valor da variável lingüística de saída inferida pelas regras nebulosas será traduzido em um valor discreto. Pode-se dizer então que, a defuzzificação é o processo inverso da fuzzificação.

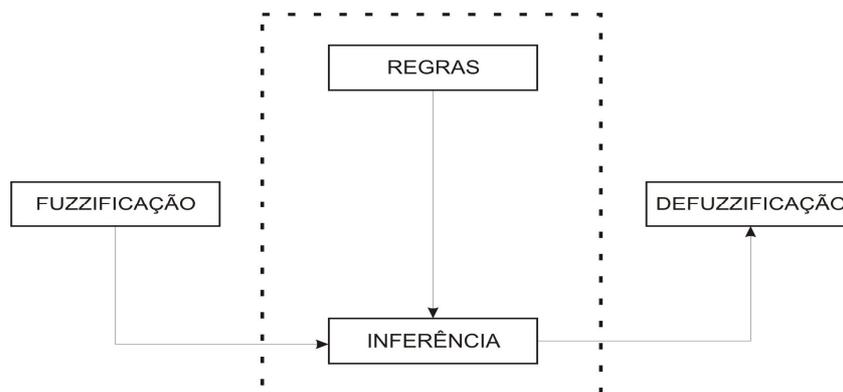


Figura 3 – Etapas de um sistema Fuzzy

No método da distância mínima considera-se o *pixel* como “puro” ou homogêneo, alocando-o a uma só classe, podendo acarretar perda de detalhes e a geração de uma imagem classificada incorreta. Na classificação nebulosa, o *pixel* tem “n” valores de graus de pertinência, determinando sua correlação com cada classe e somente após este passo é que se obtém o mapa temático (Jensen, 1996).

Foram utilizadas quatro classes em todos os processos de classificação para permitir a comparação dos resultados, tais como a imagem classificada e a matriz de confusão, que é derivada de cálculos realizados a partir da amostragem dos dados classificados, entendendo que as colunas desta matriz representam a verdade terrestre ou os dados de referência, enquanto as linhas indicam os dados classificados pelo algoritmo de classificação. A diagonal principal indica a concordância entre estes dois grupos de dados (Story E Congalton, 1986). Para satisfazer determinadas condições da classificação supervisionada foram analisados os dados das amostras coletadas, como a média dos *pixels* e o desvio padrão de cada uma das bandas do recorte da imagem, conforme podemos observar no exemplo do gráfico 1, que representa as amostras do solo exposto.

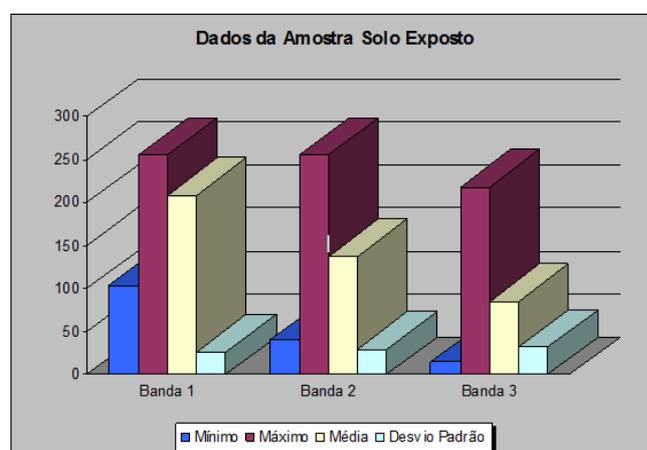


Gráfico 1 – Dados da amostra para classe Solo Exposto.

3. Resultados e Discussão

O total de amostras levantadas para cada classe em estudo na classificação supervisionada é apresentado na Tabela 1. O número máximo de *pixels* das amostras para representar determinada classe foi de 77.161 e o número mínimo 3.724, mais do que o número sugerido por Mather (1999) que é de $30p$, em que p é o número de bandas. Espera-se com isto que as classes estejam bem representadas espectralmente. Amostras essas que são informações a respeito do comportamento médio das classes e podem ser denominadas como "*pixels* de treinamento" do sistema (Novo, 1992).

Tipo de Amostra	Cor	N.º de Amostras	N.º Total de <i>Pixels</i>
Vegetação	Verde	4	77.161
Água	Azul	4	5.262
Solo exposto	Vermelho	6	60.224
Mancha urbana	Amarelo	14	3.724

Tabela 1 – Tipos de amostras e suas características para classificação

A classificação supervisionada através do método da mínima distância apresentou resultados satisfatórios, tendo em vista as características do recorte da imagem utilizada, pois

a mesma apresenta grande área com mancha urbana, conforme podemos observar no grau de acurácia, bem como, nas informações da matriz confusão apresentadas na Tabela 2.

<i>Overall Accuracy</i> = (111404/146371) 76.1107%					
<i>Kappa Coefficient</i> = 0.6242					
Classes	solo exposto	vegetação	agua	mancha	Total
Não Classificado	0	0	0	0	0
Solo exposto	56473	2603	0	572	59648
Vegetação	3751	47989	0	958	52698
Água	0	7227	5262	514	13003
Mancha Urbana	0	19342	0	1680	21022
Total	60224	77161	5262	3724	146371

Tabela 2 – Tabela composta pela Matriz de Confusão gerada a partir da Classificação Supervisionada.

Podemos observar de acordo com a matriz de confusão gerada a partir da classificação supervisionada (Gráfico 2), que existe um bom grau de acurácia nos dados classificados, no entanto, a classe da mancha urbana gerou muita confusão com as outras classes, o que era esperado por tratar-se de uma classe com resposta espectral muito diversificada.

De acordo ainda com a análise da matriz de confusão apresentada na Tabela 2, o grau de acurácia total foi de mais de 76%, no entanto, o resultado poderia ser melhor se caso as amostras da mancha urbana pudessem ser mensuradas com maior representatividade da cena, haja vista que na coleta das referidas amostras houve interferência de dados amostrais de outras classes.

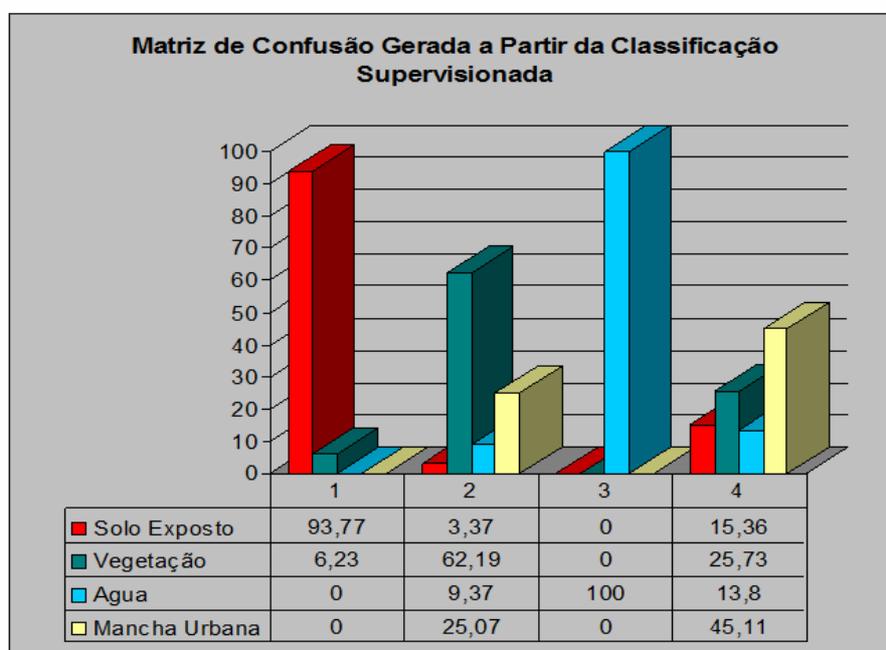


Gráfico 2 – Matriz de Confusão Gerada a partir da Classificação Supervisionada em porcentagem.

Já na classificação não-supervisionada da imagem de alta resolução espacial, realizada através da extensão denominada Fuzzy K-Means, houve apresentação de resultados insatisfatórios, conforme pode ser verificado na Figura 4.

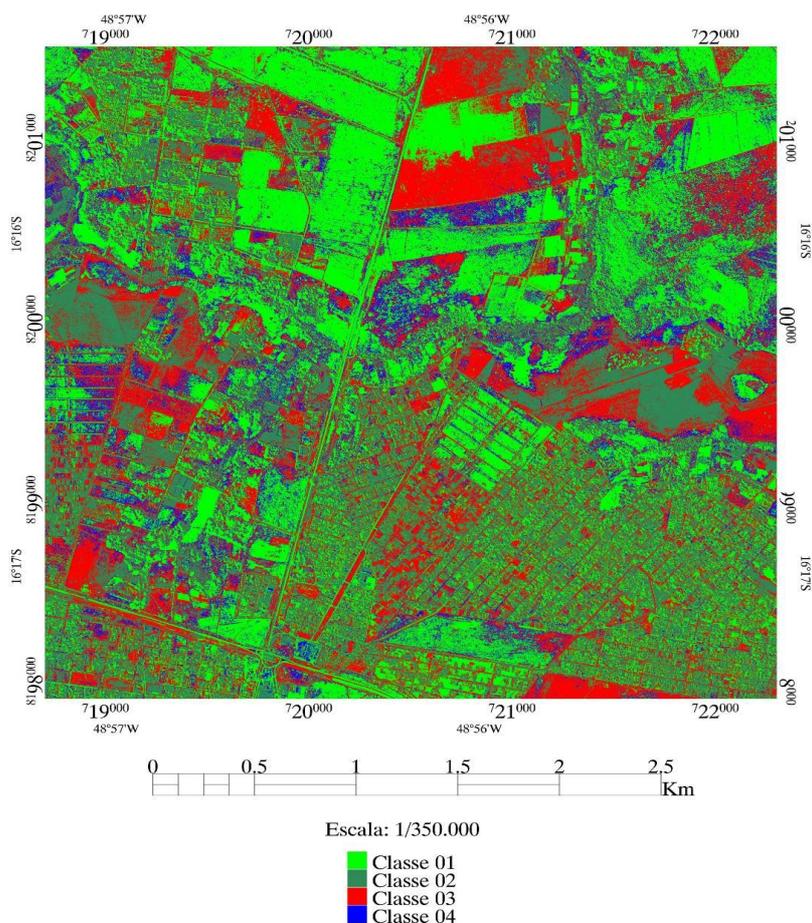


Figura 4 – Carta imagem da classificação não-supervisionada

O algoritmo apresentou grande confusão nas separações das classes, visto que este tipo de classificação, das k-médias, inicialmente divide o conjunto de *pixels* em k grupos, faz a média de cada grupo, e em seguida calcula a distância Euclidiana entre cada *pixel* do grupo e a média calculada. O erro, referente ao somatório destas distâncias, tende a ser minimizado pela movimentação de *pixels* entre os grupos até que se atinja o mínimo erro possível e os *pixels* não possam mais ser movimentados (Anderberg, 1973 e Hartigan, 1975). No algoritmo das k-médias, para diferentes partições iniciais dos *pixels* têm-se diferentes agrupamentos finais.

Sendo assim o algoritmo buscou automaticamente alinhar em classes as informações do recorte, mas os padrões amostrados não representaram as mesmas, criando assim classes que não corresponderam as buscadas (Solo Exposto, Vegetação, Água e Mancha Urbana), conforme pode ser observado na Tabela 3.

<i>Overall Accuracy</i> = (36000000/36000000) 100.0000%					
<i>Kappa Coefficient</i> = 1.0000					
Classes	Não Classificados	Classe 01	Classe 02	Classe 03	Classe 04
Não Classificado	0	0	0	0	0
Classe 01	0	7720980	0	0	0
Classe 02	0	0	14387955	0	0
Classe 03	0	0	0	9414932	0
Classe 04	0	0	0	0	4476133
Total	0	7720980	14387955	9414932	4476133

Tabela 3 – Tabela composta pela Matriz de Confusão gerada a partir da Classificação não-supervisionada.

Resultado esse que foi agravado pelo fato da imagem possuir baixa resolução espectral, trabalhando apenas na faixa do visível (450 nm a 690 nm), bem como a utilização de apenas um recorte de 6.000 x 6.000 *pixels* devido à restrição da quantidade dos mesmos para utilização da extensão Fuzzy K-Means de Mort Canty.

A fim de avaliar a qualidade do classificador Fuzzy, foi calculada uma matriz precisão dos resultados, possibilitando a análise de um nível de acurácia da imagem classificada. Tomando-se como base que a classificação supervisionada represente a verdade terrestre, foi comparada com classificação gerada pelo algoritmo Fuzzy, num modo *pixel a pixel* e confrontando classe a classe (Figura 5).

Uma das características mais importantes na matriz de confusão é o fato de mostrar os erros de inclusão dos *pixels* que não pertencem às classes a elas atribuídas. Na matriz de confusão apresentada podemos destacar a confusão gerada entre as classes e a acurácia total menor do que a obtida nas outras classificações.

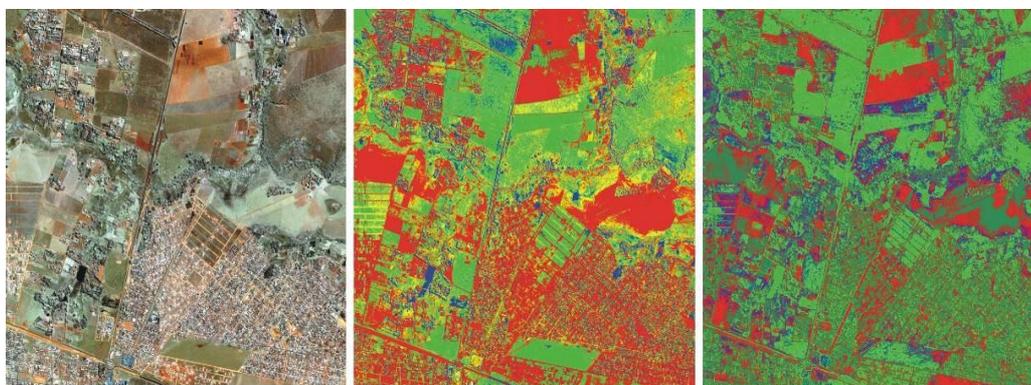


Figura 5 – Composição colorida, Classificação supervisionada e Classificação não-supervisionada

4. Conclusões

Utilizando processos de classificação distintos, pode se perceber que a qualidade de um sistema Fuzzy, depende da escolha de várias regras que sejam adequadas a uma boa modelagem dos conjuntos pertinentes a variável e a correta escolha do método de defuzzificação, embora se perceba que não é interessante a sua utilização em imagens de alta resolução espacial devido ao fato das mesmas não possuírem aporte dos dados dos comprimentos de onda fora do visível.

A classificação não-supervisionada pode ser uma opção mais adequada quando não se podem definir, através da análise visual, os elementos da cena da área de interesse, impossibilitando assim a obtenção de amostras que representem com maior fidelidade a verdade terrestre.

O método proposto, que utilizou um algoritmo baseado na lógica Fuzzy para classificação não-supervisionada, não conseguiu discriminar os padrões buscados em cada classe, que foram: Solo exposto, Vegetação, Água e Mancha Urbana. O algoritmo em questão gerou muita confusão com as classes obtidas, principalmente pela diversidade de dados apresentados no recorte utilizado, todavia, de acordo com os dados obtidos, estabelece um padrão razoável para utilização em cenas com composição restrita de dados, como por exemplo, cenas que possuam somente dados de vegetação e água.

Diferentemente do método proposto, a classificação supervisionada, pelo método da Mínima Distância, apresentou resultados significativos. Visto que pelo fato da imagem possuir boa resolução espacial, foi possível determinar amostras de boa qualidade, que representaram com fidelidade as classes buscadas no processo o que levou a obtenção de resultados desejáveis e intrinsecamente mais próximos à realidade terrestre.

A análise dos dados revelou que os vários classificadores existentes, devem ser usados de acordo com as características da imagem (Resolução espacial, espectral etc), finalidade do projeto a ser desenvolvido, custos envolvidos, disponibilidade técnica de informações do local de estudo, entre outros para que o produto esteja de acordo quantitativamente e qualitativamente com a realidade terrestre.

5. Referências Bibliográficas

- Kuo, C. et al; Identification of urban characteristic using Ikonos high resolution satellite image. In: Conferência sobre Sensoriamento Remoto, p. 22, 2001, Singapura.
- Shackelford, A.K.; Davis, C.H. A Fuzzy classification approach for high-resolution multispectral data over urban areas. In: IEEE International Geoscience and Remote Sensing Symposium, p. 1621-1623, 2002.
- CHENG, H. D. et al; Color image segmentation: advances and prospects. Pattern Recognition, v. 34, p. 2259-2281, 2001.
- Lillesand, T.; Kiefer, R.W. Remote sensing and image interpretation. 3.ed. New York: John Wiley & Sons, 1994.
- Richards, J. A.; JIA, X. Remote sensing digital image analysis - An introduction. 3.ed. Berlim: Springer-Verlag, 1999.
- Schowengerdt, R. A. Techniques for image processing and classification in remote sensing. London: Academic Press, 1983.
- Jensen, J. R. Thematic information extraction: Image classification. In: Introductory digital image processing. 2 ed. New Jersey: Prentice Hall, 1996. p. 197-252.
- Story, M.; Congalton, R.G. Accuracy assessment: a user's perspective. photogrammetric engineering and remote sensing, v. 52, n. 3, p. 397-399, 1986.
- Mather, P.M. Computer processing of remotely-sensed images. John Wiley & Sons, New York. 1999.
- Novo, E. M. L. M. Sensoriamento remoto: princípios e aplicações. São Paulo: Editora Blucher, 2. ed. p. 308. 1992.
- Anderberg, M.; "Cluster analysis for applications", Academic Press, New York and London (1973).
- Hartigan, J.; "Classification (2nd edition)", Chapman and Hall/CRC Press, London, (1975)
- T. Duda; Canty, M. J. (2002), Unsupervised classification of satellite imagery: choosing a good algorithm, international journal of remote sensing, 23(11) 2193-2212. Disponível em: <<http://mcanty.homepage.t-online.de/>>. Acesso em março de 2010.