

CLASSIFICAÇÃO SUPERVISIONADA POR MÁXIMA VEROSSIMILHANÇA GAUSSIANA COMO FERRAMENTA PARA MONITORAMENTO DE ÁREAS DE VEGETAÇÃO EM REGIÕES METROPOLITANAS

Fernanda Veren da Silva¹

Rute Henrique da Silva Ferreira²

Resumo: O sensoriamento remoto tem se mostrado uma grande ferramenta para o mapeamento do crescimento urbano nas regiões com crescente urbanização. A metodologia mais utilizada é a classificação digital de dados multiespectrais, realizada de forma supervisionada ou não supervisionada. Este estudo tem por objetivo destacar as áreas de vegetação que sofreram redução em decorrência da implantação de empreendimentos, consequentemente a expansão urbana, a partir da classificação supervisionada por Máxima Verossimilhança Gaussiana (MAXVER), utilizando de imagens digitais do satélite Landsat 5, tendo como área de estudo a região Metropolitana de Porto Alegre, Rio Grande do Sul. As imagens orbitais Landsat 5 com data de passagem nos anos 2005 e 2011, foram coletadas no banco de imagens do Instituto Nacional de Pesquisas Espaciais (INPE) e foram classificadas no *software MultiSpec* utilizando as classes urbano, vegetação, água, solo e areia. Constatou-se, com uma acurácia global superior a 90% para todas as classes, uma redução de 19,8 % da área de vegetação e um aumento de 16,1 % na área de urbanização, evidenciando o impacto da urbanização na redução das áreas de vegetação.

Palavras-chave: Sensoriamento Remoto; Classificação Supervisionada; Urbanização; Mudança no uso e Cobertura da Terra; Landsat 5.

Abstract: Remote sensing has proven to be a great tool for mapping urban growth in regions with increasing urbanization. The most used methodology is the digital classification of multispectral data, performed supervised or unsupervised. This study aims to highlight the areas of vegetation that suffered reduction due to the implementation of projects, consequently the urban expansion, based on the classification supervised by Maximum Gaussian Likelihood (MAXVER), using digital images from the Landsat 5 satellite, having as its area metropolitan region of Porto Alegre, Rio Grande do Sul. The Landsat 5 orbital images dated in 2005 and 2011 were collected in the image bank of the National Institute for Space Research (INPE) and classified in the MultiSpec software. using the urban classes, vegetation, water, soil and sand. With an overall accuracy of over 90% for all classes, a reduction of 19.8% of the vegetation area and a 16.1% increase in the area of urbanization were observed, showing the impact of urbanization on the reduction of areas. of vegetation.

Keywords: Remote Sensing; Supervised Classification; Urbanization; Change in Land Use and Coverage; Landsat 5.

C
I
P
P
U
S

(ISSN2238-9032)

1 Curso de Engenharia Ambiental, Universidade La Salle, Canoas, Rio Grande do Sul, Brasil. E-mail para correspondência: nandaveren@globocom

2 Universidade La Salle, Canoas, Rio Grande do Sul, Brasil.

INTRODUÇÃO

A expansão urbana traz consigo a necessidade da utilização dos recursos naturais e a demanda elevada destes recursos resulta em alterações no meio físico, causando assim um desequilíbrio na natureza e nas interações atmosféricas. As áreas que se encontram em constante modificação pelas inúmeras formas de ocupação do solo resultam em modificações meteorológicas, gerando novos microclimas. A poluição do ar, o aumento de empreendimentos, a impermeabilização do solo e principalmente a redução da vegetação desencadeiam esses desequilíbrios (OLIVEIRA et al, 2014).

Um assunto que vem sendo bastante discutido na atualidade é a percepção dos riscos e dos conflitos ambientais existentes no meio ambiente urbano. Nesse meio interagem diferentes grupos de seres vivos, e é onde indivíduos e comunidades humanas distintas convivem com as dinâmicas: econômica, política social e cultural. Esse estilo de vida da sociedade contemporânea, atualmente, vem sendo responsável por influências diretas e indiretas na vegetação presente no meio urbano, alterando assim a quantidade, qualidade e variedade, ocasionando a redução e escassez dos mesmos.

Esta expansão da urbanização resulta em um nível acentuado do uso do solo para a construção de novos empreendimentos. Sendo assim, faz-se necessária a atuação do homem no ambiente com o auxílio de mapas de uso da terra, que são adquiridos através de imagens de satélite e através das ferramentas do sensoriamento remoto que são fontes de dados espaços-temporais permitindo uma avaliação do uso do solo de uma determinada região. Conforme Florenzano (2002), as imagens orbitais nos proporcionam uma visão de conjunto de extensas áreas terrestres, possibilitando a realização de estudos regionais e integrados, expressando a dinâmica e a transformação destes ambientes, permitindo destacar os impactos causados por fenômenos naturais e antrópicos, entre eles, a expansão urbana, o desmatamento e demais alterações do uso e ocupação da terra.

Sendo assim, para a realização de forma integrada os projetos em sistema de informações geográficas (SIG) e para o alcance de dados mais precisos e de forma rápida, uma das soluções é o uso de sistemas computacionais capazes de organizar em bancos de dados às informações previamente georreferenciadas. Deste modo, o geoprocessamento torna-se um conjunto de ferramentas capazes de reunir a cartografia e o armazenamento de dados, permitindo a realização do tratamento e a análise dessas informações, tudo isso de forma integrada, através de programas computacionais relacionados a um Sistema de Informação Geográfica (SEBUSIANI; BETTINE 2011).

O presente trabalho tem por objetivo destacar as áreas de vegetação que sofreram redução em decorrência à expansão da área urbana a partir da comparação da classificação supervisionada por Máxima Verossimilhança Gaussiana também conhecida como (MAXVER), utilizando de imagens digitais do satélite Landsat 5 TM (Thematic Mapper) nos anos de 2005 e de 2011, tendo como área de estudo a região Metropolitana de Porto Alegre, Rio Grande do Sul.

FUNDAMENTAÇÃO TEÓRICA

O Sensoriamento Remoto constitui-se em uma importante ferramenta para o monitoramento e análise de extensas áreas da terra como os espaços urbanos, contribuindo para o planejamento e, conseqüentemente minimizando os impactos negativos gerados ao meio ambiente.

Na atualidade, o sensoriamento remoto vem sendo largamente aplicado para o monitoramento de coberturas vegetais, principalmente para seu comportamento espacial e/ou fisiológico. As distintas áreas do conhecimento, cujo foco ou objeto de estudo se pautam na observação e análise da vegetação (agronomia, biologia, geociências, silvicultura) vêm cotidianamente utilizando e aprimorando as formas de utilização desse recurso (WENG, 2010).

É notável como a importância dos satélites vem aumentando dia a dia. As notícias sobre o que ocorre no mundo, as ligações telefônicas, a internet e as imagens usadas na previsão do tempo e no monitoramento dos ambientes terrestres são alguns exemplos dos benefícios que podem ser obtidos pela utilização de um satélite (FLORENZANO, 2008).

As alterações causadas no meio ambiente, decorrentes das atividades antrópicas, principalmente o aumento desordenado da urbanização, resultam em impactos no meio que são intensificados pelas incessantes mudanças do espaço, resultando assim, em um desequilíbrio ambiental.

A extração da cobertura vegetal do ecossistema, feita pelo homem de forma predatória, somada com as queimadas, são sem dúvida os fatores mais causadores destes desequilíbrios ambientais, alterando assim, as funções atmosféricas que se propagam cada vez mais acarretando na extinção da biodiversidade.

Nessa linha de raciocínio, Rocha (2002) afirma que se tem notado uma elevada degradação do meio ambiente terrestre, provocado por um aspecto frequente, usufruidor e rejeitável, dos recursos naturais do meio, como se fossem inesgotáveis, tendo como consequência a poluição da água, do solo, do ar e o aumento do desmatamento que é o tema ambiental que mais sofre com este descuido.

Com outra visão Rosa, (1992) faz uso da expressão “uso da terra” como sendo uma forma para se compreender a ocupação do espaço da terra pelo homem, com isto, é importante levar em conta a forma de como este espaço está sendo ocupado, se de forma correta conforme a região.

A qualidade ambiental não é somente um somatório das qualidades dos componentes do meio, mas é uma condição ligada à qualidade de vida da sociedade (BOTELHO; SILVA, 2004).

Não é possível acompanhar de forma tão rápida as transformações das ações humanas sem o uso das tecnologias. Assim, com o uso do Sensoriamento Remoto podemos monitorar, direcionar, organizar e explorar a área de interesse (ou espaço).

A inserção do Sensoriamento Remoto com os diferentes planos de informação da paisagem, suas características e processos, colaboram para determinação destas áreas conflitantes e a tomada de decisão em curto espaço de tempo e alta confiabilidade em âmbito socioeconômico, além de ambiental, segundo Florenzano (2002).

Para Florenzano (2002), Sensoriamento Remoto é a tecnologia que permite obter imagens e outros tipos de dados da superfície terrestre, através da captação e do registro da energia refletida pela superfície, sem o contato físico entre o sensor e a superfície terrestre. Com isso, obtém-se a otimização na aquisição de dados. Além disso, torna-se possível realizar trabalhos temporais com o objetivo de identificar as transformações no ambiente, bem como os impactos causados pela ação do homem através do uso e ocupação do solo.

Inserida no sensoriamento remoto, uma das técnicas utilizadas para o monitoramento de áreas com vegetação é o reconhecimento de padrões, que permite lidar com a classificação e descrição de objetos. De acordo com Rocha (1999), um projeto de reconhecimento de padrões envolve normalmente:

- Extração de características dos objetos a classificar (ou a descrever);
- Seleção das características mais discriminativas;
- Construção de um classificador (ou descritor).

O primeiro passo em um processo de classificação multiespectral é o treinamento. Treinamento é o reconhecimento da assinatura espectral das classes. Existem basicamente duas formas de treinamento: supervisionado e não supervisionado.

Quando existem regiões da imagem em que o usuário dispõe de informações que permitem a identificação de uma classe de interesse, o treinamento é dito supervisionado. Para um treinamento supervisionado o usuário deve identificar na imagem uma área representativa de cada classe. É importante que a área de treinamento seja uma amostra homogênea da classe respectiva, mas ao mesmo tempo deve-se incluir toda a variabilidade dos níveis de cinza. Recomenda-se que o usuário adquira mais de uma área de treinamento, utilizando o maior número de informações disponíveis, como trabalhos de campo, mapas, etc. Para a obtenção de classes estatisticamente confiáveis, são necessários de 10 a 100 *pixels* de treinamento por classe. O número de *pixels* de treinamento necessário para a precisão do reconhecimento de uma classe aumenta com o aumento da variabilidade entre as classes. (INPE)

Quando o usuário utiliza algoritmos para reconhecer as classes presentes na imagem, o treinamento é dito não supervisionado. Ao definir áreas para o treinamento não supervisionado, o usuário não deve se preocupar com a homogeneidade das classes. As áreas escolhidas devem ser heterogêneas para assegurar que todas as possíveis classes e suas variabilidades sejam incluídas. Os *pixels* dentro de uma área de treinamento são submetidos a um algoritmo de agrupamento (*clustering*) que determina o agrupamento do dado, numa feição espacial de dimensão igual ao número de bandas presentes. Este algoritmo assume que cada grupo (*cluster*) representa a distribuição de probabilidade de uma classe.

Segundo Jensen (2005), em estudos ambientais, a metodologia mais utilizada para analisar dados e retirar informações se relaciona à classificação digital baseada em dados multiespectrais, podendo ser executada de forma supervisionada ou ainda de forma não-supervisionada. Quando executada de forma supervisionada, pode ser definida como o processo de utilizar amostras de identidade conhecida para classificar *pixels* de identidade desconhecida. Nesta, o analista busca identificar as áreas específicas que representem exemplos homogêneos das feições (RIBEIRO, 2004), que baseia-se na definição das classes e na extração de amostras executadas pelo usuário, que utiliza-se destas para gerar padrões e, assim, rotular os pixels como pertencentes a uma determinada classe (ANDRADE et al., 2013).

Dentro do conjunto de algoritmos mais utilizados para a classificação de imagens orbitais está o de Máxima Verossimilhança Gaussiana (CAMPBELL, 1987). Ele usa a média e a covariância das amostras para marcar a um *pixel* desconhecido uma classe identificada. Compreendido esses parâmetros, é computado a probabilidade estatística de um *pixel* fazer parte de uma determinada classe. Após a análise desta probabilidade para cada uma das classes, o *pixel* é declarado a uma classe cuja probabilidade tenha sido mais alta, ou sendo o caso, nenhuma delas (RIBEIRO, 2003).

A experiência prática utilizando dados multiespectrais de sensoriamento remoto tem mostrado que a função densidade de probabilidade multivariada com distribuição normal descreve bem o comportamento destes dados. Assim, a função de decisão para o classificador Máxima Verossimilhança é dada por:

$$G_i(X) = -\frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i) \quad (1)$$

onde:

μ_i é o vetor de média

Σ_i é a matriz de covariância

Para a avaliação da acurácia, é utilizada a matriz de contingência (Richards, 2006). A partir de sua análise pode-se definir:

- Acurácia do usuário (*user's accuracy*): informa o grau de confiança na imagem classificada. Ou seja, a probabilidade de um *pixel* classificado na classe w_i realmente pertencer a w_i .
- Acurácia do produtor (*producer's accuracy*): informa a capacidade do classificador de reconhecer que uma amostra pertence à classe w_i dado que ela realmente pertence a w_i .
- Acurácia Global =
$$\frac{\sum a_{ij} \quad \forall i=j}{\sum a_{ij} \quad \forall i,j} \quad (2)$$

Também é realizada a distinção entre erros de **omissão** (*pixels* pertencentes à classe de interesse que o classificador não reconheceu) e erros de **comissão** (*pixels* que pertencem a outras classes, mas o classificador rotulou como pertencente à classe de interesse). O primeiro é apresentado na última coluna da matriz de confusão, enquanto o segundo na última linha.


Richards (2006) aponta três métodos utilizados para a avaliação da acurácia: ressubstituição, *Hold Out* e *Leave One Out*. A ressubstituição calcula o erro do classificador usando o próprio conjunto de treinamento. No *Hold Out*, as amostras são divididas em amostras de treinamento e amostras de testes e o *Leave One Out* consiste na remoção de um conjunto de *pixels* de treinamento, treinando-se o classificador com o restante e usando-se o classificador treinado para rotular os *pixels* deixados para trás. O *pixel* é substituído e outro é retirado e o processo é repetido. Isso é feito para todos os *pixels* no conjunto de treinamento.

Nesse trabalho foi utilizada a classificação supervisionada por Máxima Verossimilhança Gaussiana e a matriz de contingência foi construída utilizando-se o método da ressubstituição.

MATERIAIS E MÉTODOS


A área selecionada para o presente estudo corresponde à região metropolitana de Porto Alegre, no estado do Rio Grande do Sul, situada em torno das coordenadas geodésicas Latitude Sul (-29.38610) e Longitude Oeste (-52.18590).

Figura 1: Localização da área de estudo, imagem de 2005.



Fonte: INPE.

Figura 2: Localização da área de estudo, imagem de 2011.



Fonte: INPE.

Foram utilizadas imagens do Satélite Landsat 5, coletadas gratuitamente no banco de imagens do Instituto Nacional de Pesquisa Espaciais (INPE). No intuito de coletar dados a distância, interpretar e visualizar a utilização dos recursos naturais, tendo início na década de 1970 o programa Landsat (*Land Remote Sensing Satellite*), coordenado pela Agência Espacial Norte Americana (NASA), tem por objetivo monitorar os recursos naturais da terra de forma contínua, fornecendo cenas em determinados intervalos de tempo (FLORENZANO, 2011). Tendo início a sua operação no ano de 1984, o satélite Landsat 5 possui a bordo o sensor TM (Thematic Mapper) que permite o imageamento da superfície terrestre a partir de sete bandas espectrais distintas, demonstrando ser uma ferramenta de alta versatilidade quanto às suas possibilidades de aplicação.

Para este estudo, foram selecionadas duas imagens do sensor TM, ambas com órbita/ponto 221/81, a primeira com data de passagem em 2005, e a mais recente com data de passagem em 2011.

Tabela 1 - Identificação das imagens estudadas.

Data	Sensor	Satélite	Órbita	Ponto
2005-05-04	TM	Landsat 5	221	81
2011-05-05	TM	Landsat 5	221	81

Buscou-se priorizar as imagens que apresentavam menor percentual da cobertura de nuvens na região da pesquisa, com intuito de minimizar qualquer interferência nesse sentido. No momento do início do projeto, a área de mapeamento foi limitada a um menor corte quadrado possível que mirasse parte da região metropolitana de Porto Alegre.

Em seguida, as imagens foram combinadas em sistema de cores *Red-Green-Blue* (RGB) no *software* MultiSpec, a composição colorida com melhor resultado para estudo da região foi a R3-G2-B1, também denominada cor verdadeira, para as imagens TM/Landsat. Nesta composição as imagens foram submetidas às seleções de amostras de treinamento necessárias na classificação supervisionada. Para auxiliar na interpretação visual da área foi utilizado o Google Earth como ferramenta de apoio, permitindo delimitar com uma maior precisão as amostras para as cinco classes distintas: Urbano, Vegetação, Água, Solo e Areia. As áreas de treinamento supervisionado foram definidas por meio de polígonos, levando em consideração a cor, brilho e textura emitida por cada *pixel* da imagem. Assim sendo, ainda no MultiSpec foram realizadas as classificações, pelo método supervisionado com o classificador Máxima Verossimilhança Gaussiana (*Maximum Likelihood*).

O classificador Máxima Verossimilhança Gaussiana (Maxver) utiliza como método a informação espectral e espacial de cada *pixel* de forma estatística, que infere a probabilidade de um *pixel* desconhecido pertencer a uma ou outra classe a partir das amostras identificadas e fornecidas pelo analista através da coleta e treinamento. O Maxver é um algoritmo paramétrico que associa classes considerando pontos individuais da imagem e assume que essas classes possuem distribuição normal, a partir dos parâmetros definidos e uma amostra de *pixels* adquiridas (SILVA et al, 2011; LEITE ; ROSA, 2012).

A acurácia dos classificadores supervisionados foi verificada através da análise das matrizes de contingência, também conhecidas como matriz de confusão, destacando a acurácia global de cada classificação.

RESULTADOS E DISCUSSÕES

Para cada data, foi realizada a classificação, a construção da imagem temática com os dados da classificação e a análise da matriz de contingência.

A figura 3 mostra a imagem de 2005 e a respectiva imagem temática classificada. A figura 4 mostra a imagem de 2011 e a respectiva imagem temática classificada. Já as tabelas 2 e 3 mostram, respectivamente, as matrizes de contingência para a classificação de 2005 e 2011.

Figura 3- Comparação de imagem original e temática de 2005.




Figura 4- Comparação de imagem original e temática de 2011.




Tabela 2-Matriz de Contingência do Maxver em imagem TM de 2005.

	Urbano	Vegetação	Água	Solo	Areia	Total Classificadas	Exatidão Produtor
Urbano	75	0	0	0	0	75	100%
Vegetação	0	88	0	0	0	88	100%
Água	0	3	64	0	0	64	100%
Solo	0	0	0	143	0	143	100%
Areia	0	0	0	0	42	42	100%
Total Coletadas	75	88	64	143	42	412	
Exatidão Usuário	100%	100%	100%	100%	100%		100%
Acurácia Global	100%						

Tabela 3- Matriz de Contingência do Maxver em imagem TM de 2011.

	Urbano	Vegetação	Água	Solo	Areia	Total Classificadas	Exatidão Produtor
Urbano	50	0	0	0	0	50	100%
Vegetação	0	78	0	0	0	78	100%
Água	0	0	87	0	0	87	100%
Solo	0	0	0	39	0	39	100%
Areia	0	0	0	0	47	47	100%
Total Coletadas	50	78	87	39	47	301	
Exatidão Usuário	100%	100%	100%	100%	100%		100%
Acurácia Global	100%						

Após a classificação, também foi construída uma tabela com a porcentagem ocupada por cada classe nas imagens de 2005 e 2011, conforme mostra a tabela 4.

Tabela 4- Porcentagem ocupada por classe em imagem TM de 2005 e 2011.

	2005		2011	
	Porcentagem	Área (ha)	Porcentagem	Área (ha)
Urbano	32%	603.467,91	48,1%	883.422,72
Vegetação	27,5%	504.583,29	7,7%	141.955,65
Água	25,9%	78.783,75	22,1%	108.401,40
Solo	4,3%	475.782,12	5,9%	406.569,96
Areia	9,5%	174.111,93	16,1%	296.379,27
Total	100%	1.836.729,00	100%	1.836.729,00

Verificou-se que a acurácia global para o ano de 2005 resultou-se a mesma para a acurácia global para o ano de 2011. Assim, o classificador supervisionado mostrasse uma ótima ferramenta para analisar as amostras de treinamento em suas situações específicas. Situações essas, que na classe denominada Vegetação, obteve-se uma redução de 19,8% dentro de um intervalo de tempo de seis anos, e a classe denominada Urbano, obteve-se um aumento de 16,1%.

CONCLUSÕES

A partir dos resultados obtidos e através da avaliação das matrizes de contingência e mapeamentos gerados com o classificador Máxima Verossimilhança Gaussiana, pode-se verificar que a aplicação da geotecnologia pode auxiliar no monitoramento de áreas geográficas ambientais por apresentar informações precisas.

As técnicas aplicadas nas imagens utilizadas de 2005 e 2011 possibilitaram a identificação e a quantificação de áreas com cobertura de vegetação. Conclui-se que as áreas de vegetação diminuíram ao longo de seis anos dando lugar a expansão de áreas urbanas, representando assim, um cenário negativo na questão ambiental que nos permite uma visão ampla da forma como o homem se relaciona com o ambiente.

Destaca-se que neste estudo as imagens utilizadas foram de Landsat, pois estes sensores possibilitam a especificação das classes mais decorrentes em ambientes naturais. Porém, a eficiência faz-se limitada quando deseja-se estudar regiões menores.

REFERÊNCIAS

- ANDRADE, R.G.; RODRIGUES, C. A. G.; SANCHES, I. D. A.; TORRESAN, F. E.; QUARTAROLI, C. F. Uso de técnicas de sensoriamento remoto na detecção de processos de degradação de pastagens. **Engenharia na Agricultura**, v. 21, n. 3, p. 234-243, 2013.
- BERNARDO, N.; BERNARDO, M. R. **Análise de fragilidade ambiental com técnicas de geoprocessamento e sensoriamento remoto aplicadas aos municípios de Petrópolis e Teresópolis, Rio de Janeiro**. 2013. 117 f. Trabalho de conclusão de curso. Universidade Tecnológica Federal do Paraná. Disponível em: <http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/1094/1/LD_COEAM_2012_2_06.pdf>.
- CAMPBELL, J. B., Introduction to remote sensing. New York: The Guilford Press, 1987. 551 p.
- FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002. 97 p.
- FLORENZANO, T. G. 2011. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina de Textos. 128p.
- FLORENZANO, T. G. 2008. **Os satélites e suas aplicações**. São Paulo.
- FIGUEIREDO, Divino. **Conceitos básicos de sensoriamento remoto**. Disponível em: <http://www.andersonmedeiros.com/wp-content/uploads/2013/04/conceitos_sm.pdf>.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Manual: Tutorial de Geoprocessamento, 2006. Disponível em: <http://www.dpi.inpe.br/spring/portugues/tutorial/descricao_geral.html>.
- JENSEN, J. R. 2005. **Introductory Digital Image Processing: A Remote Sensing Perspective**. 3rd Edition, Upper Saddle River: Prentice-Hall, 526 p.

- LEITE, E. F.; ROSA, R. 2012. Análise do uso, ocupação e cobertura da terra da bacia hidrográfica do Rio Formiga, Tocantins. **Revista Eletrônica de Geografia**. v. 4, n. 12, p. 90-106.
- OLIVEIRA, G. C.; MARTINS, V. S.; FILHO, E. I. F. 2014. Classificação supervisionada como ferramenta para avaliação da dinâmica do uso e cobertura do solo. **Enciclopédia Biosfera**. Centro Científico Conhecer – Goiânia, v. 10, n. 18; p. 935.
- Resolução CONAMA nº 302, de 20 de março de 2002. **Dispõe sobre os parâmetros, definições e limites de Áreas de Preservação Permanente de reservatórios artificiais e o regime de uso do entorno**. Disponível em: <https://www.pjf.mg.gov.br/secretarias/sma/app/arquivos/conama302_02.pdf>.
- RIBEIRO, R. M. P. 2004. **Avaliação de métodos de classificação de imagens IKONOS II para o mapeamento da cobertura terrestre**. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa. 53p.
- RICHARDS, J. A.; JIA, X.; **Remote Sensing Digital Image Analysis**. New York: Springer, 2006. Third Edition.
- ROCHA, C. H. B. **Geoprocessamento, Tecnologia Transdisciplinar**. 2. Ed –Revista Atualizada e Ampliada. Juiz de Fora - MG, 2002.
- ROSA, R. **A utilização de imagens TM/Landsat em levantamento de uso do solo**. Universidade Federal de Uberlândia. Departamento de Geografia.
- SALLES, M. C. T. **Expansão Urbana e Conflito Ambiental: Uma Descrição do Município de Mossoró, RN – Brasil**. 2013. 10f. Disponível em: <<http://www.scielo.br/pdf/sn/v25n2/a06v25n2.pdf>>.
- SEBUSIANI, H. R. V.; BETTINE, S. D. Metodologia de análise do uso e ocupação do solo em micro bacia urbana. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 7, n. 1, p. 256-285, jan-abr/2011.
- SILVA, A. F.; BARBOSA, A. P.; ZIMBACK, C. R. L.; LANDIM, M. B. 2011. Classificadores de imagens por técnicas de sensoriamento remoto e geoestatística. In: II Simpósio de Geoestatística Aplicada em Ciências Agrárias. Botucatu-SP.
- UNIVERSIDADE LA SALLE. **Manual para apresentação de artigos científicos da Universidade La Salle**. 3. ed. Canoas, RS, 2019. 73 p. Disponível em:<<http://www.unilasalle.edu.br/uploads/files/fd99c0129618fdc365e4b54f14ee3edc.pdf>>.
- WENG, Q. **Remote Sensing and GIS Integration: Theories, Methods, and Applications**. New York: McGraw-Hill, 2010. 397p.

