

Uso de algoritmos genéticos para a classificação de imagens de
sensoriamento remoto

Jorge Antonio Silva Centeno ¹

Marcio Augusto Reolon Schmidt²

¹Curso de Pós Graduação em Ciências Geodésicas – UFPR

²bolsista de Engenharia Cartográfica

¹centeno@geoc.ufpr.br

²ocade@cw.matrix.com.br

USO DE ALGORITMOS GENÉTICOS PARA A CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO

RESUMO

No presente trabalho aborda-se a utilização de técnicas de inteligência artificial para classificar imagens de satélite. O objetivo é desenvolver uma metodologia para mapear e atualizar os levantamentos da cobertura do solo, baseada no princípio dos algoritmos genéticos. Como fontes de dados são adotadas imagens de satélite, dos sensor Landsat-TM. O processo de tomada de decisão é executado através de um conjunto de regras simples, para as quais vários parâmetros devem ser definidos. Estes parâmetros são estimados utilizando o processo de aprendizado dos algoritmos genéticos. Para isto, amostras representativas das classes são escolhidas nas imagens multiespectrais e um processo seletivo, similar ao processo evolutivo da natureza, é empregado para otimizar a solução que fornece o melhor conjunto de parâmetros. Com este resultado, a imagem toda pode ser classificada. Testes usando imagens multiespectrais, com bandas das regiões infravermelha e visível do espectro, foram realizados para avaliar a metodologia. Os testes serviram para analisar efeito da variação dos parâmetros que controlam os algoritmos genéticos, como o tamanho da população e o número de iterações necessários para resolver cada situação.

ABSTRACT

The present work describes an application of techniques of artificial intelligence to satellite images classification. The aim is to develop a methodology to classify land cover using multispectral images, based on the principles of the genetic algorithms. Landsat - TM images of Brazil are used as data source. The classification is performed using a simple rule-based decision process. A set of parameters, that

control the decision making, are necessary and they are estimated using the evolutionary concept of the genetic algorithms. For this purpose, representative samples of each class are chosen in the multispectral image and they are used to start an iterative search process of the optimal solution. In each iteration, a set of possible solutions are estimated and the result of the classification of the training pixels is compared to the true classification (known from other sources). The best estimates are kept and combined, using genetic operations that resemble natural evolution, and later used in a new iteration. The optimized solution is then used to classify the complete image. Tests using multispectral data, with bands of the infra-red and visible regions of the spectrum are presented and discussed. The tests serve to analyze the effect of the variation of the parameters that control the genetic algorithms, as the size of the population and the number of iterations necessary for each problem.

1. INTRODUÇÃO

Uma das classificações mais simples usadas no sensoriamento remoto é o método dos paralelepípedos. Estes método consiste em definir os limiares de cada classe presente em uma imagem dentro de um sistema de cores. Justamente a definição destes limiares que se torna o problema para uma boa classificação. Uma solução pode ser obtida aplicando conceitos da inteligência artificial, neste caso os algoritmos genéticos. O presente artigo descreve o resultado de uma pesquisa que visa a verificar a aplicabilidade destas técnicas para classificação multiespectral de imagens multiespectrais.

2. O MÉTODO DOS HIPERCUBOS

Alternativas para a classificação de um conjunto de observações multiespectrais que não se adaptem a uma distribuição estatística podem ser encontradas aplicando – se métodos simples, como a divisão do

espaço espectral fixando limites máximos e mínimos, em cada banda para cada classe (LILLESAND E KIEFER, 1994). Isto é efetuado de uma maneira simples. Para cada classe considerada, a faixa de variação em cada banda é analisada e os limites máximo e mínimo da faixa de variação são estimados. Cada pixel na imagem, descrito pelo vetor de valores digitais ($x' = [x_1, x_2, x_3]$), é então classificado segundo um conjunto de regras simples. Para um conjunto de NB bandas espectrais ($j=1,2,3,\dots,NB$) e considerando NC classes ($i=1,2,3,\dots,NC$), um pixel com valores (x_1, x_2, \dots, x_{NC}) pertence à classe j se:

$$\text{Se } (\text{limij1} < x_j < \text{limij2})$$

sendo

limij1 e limij2 os limites inferior e superior para a classe i na banda j .

Embora o princípio seja muito simples, o problema se torna complexo quando a imagem apresenta classes espectralmente próximas ou um número elevado de classes, que podem ser confundidas e dificultam a separação mediante esta abordagem, pois podem ocorrer pixels que satisfaçam a mais de uma regra. A fixação dos limiares é portanto uma tarefa que demanda cuidado e é freqüentemente efetuada de maneira iterativa (LILLESAND E KIEFER, 1994).

3. ALGORITMOS GENÉTICOS

Algoritmos genéticos são o ramo mais conhecido da computação evolutiva, que conceitualmente apresentam um escopo mais amplo que a simples otimização (BITTENCOURT, 1998).. São métodos de busca baseados nos mecanismos de seleção natural e genética, que apresentam um modelo para aprendizagem de máquina. Enquanto os métodos de otimização e busca trabalham geralmente de forma sequencial, avaliando a cada instante uma possível solução, os algoritmos genéticos trabalham com um conjunto de possíveis soluções simultaneamente.

Dentro do conceito de algoritmos genéticos, uma solução possível é codificada numa seqüência binária e tratada como indivíduo ou genoma. Ao conjunto de indivíduos simultaneamente avaliados é dado o nome de população e, a cada indivíduo, é dado um grau ou nota de adaptação que mede a capacidade da solução deste indivíduo em resolver um dado problema. Os algoritmos genéticos não garantem uma solução ótima mas geralmente encontram soluções quase ótimas em um tempo aceitável .

Cada iteração é chamada de geração, e nela os princípios de seleção e reprodução são aplicados a uma população de candidatos. Durante o processo evolutivo, a população é avaliada – para cada indivíduo é dada uma nota ou fitness, refletindo a sua habilidade de adaptação a um determinado ambiente. Uma porcentagem dos mais aptos é mantida, enquanto o resto é descartado. Os membros mantidos pela seleção podem sofrer alterações em seu código através de mecanismos como mutações e crossovers, gerando descendentes da próxima geração. Esta é a definição de reprodução e é repetido até se obter uma resposta satisfatória (AZEVEDO ET AL, 2000).

3.1 REPRESENTAÇÃO GENÉTICA

O primeiro passo a ser considerado para a utilização de algoritmos genéticos é a representação do problema em uma estrutura na qual o algoritmo possa trabalhar adequadamente (BRAGA ET AL., 2000). No caso da classificação por paralelepípedos, cada classe demanda $2 \times NB$ parâmetros, ou seja, considerando NC classes um total de $2 * NC \times NB$ parâmetros tornam-se necessários. Isto pode ser codificado como uma cadeia. Por exemplo, para 3 bandas e uma classe ter-se-ia a seguinte cadeia (*lim111, lim112, lim121, lim122, lim131, lim132*). Para um número maior de classes, a seqüência é aumentada (*lim111, lim112, ..., lim132, lim211, lim212, ..., lim232, ..., limNC11, limNC12, ..., limNC32*). Esta cadeia é considerada, que para fins do presente estudo, como o “genoma“ de um indivíduo. Os indivíduos são representados por vetores binários. A representação binária é independente do problema pois uma vez encontrado o vetor, as operações padrão podem ser utilizadas.

3.2. OPERADORES GENÉTICOS

Os operadores genéticos básicos utilizados neste trabalho são a seleção, o cruzamento, a mutação e o elitismo, descritos em AZEVEDO ET AL, 2000 e BRAGA ET AL. 2000.

Seleção: O processo de seleção determina quais indivíduos da população podem participar da fase de reprodução. Os indivíduos são selecionados de acordo com sua adequação às condições impostas, sua qualidade. Assim os indivíduos melhor adaptados tem maiores chances de participar da reprodução. O princípio básico dos algoritmos genéticos é que um critério de seleção faça com que uma população inicial gere, após algumas gerações, indivíduos mais aptos. A maioria dos métodos de seleção é definida para escolher preferivelmente indivíduos com maiores notas, ou graus, de aptidão, embora não exclusivamente (em alguns casos é preferível que se mantenha a diversidade da população).

Reprodução: Os indivíduos escolhidos na fase de seleção participam da fase de reprodução, em que podem ser combinados ou modificados, produzindo os indivíduos da próxima geração. Os principais operadores de reprodução são: cruzamento e mutação. Eles são utilizados para assegurar que a nova geração apresente novos indivíduos (soluções), mantendo características desejáveis adquiridas em gerações anteriores.

cruzamento: é o operador responsável pela combinação das características genéticas dos pais durante a reprodução, permitindo que elas sejam herdadas pelas próximas gerações. Neste trabalho, foi utilizado o operador de cruzamento de ponto único, ou seja um ponto de cruzamento, que é um ponto entre dois genes de um cromossomo, é escolhido, e a partir deste ponto, as informações genéticas dos pais são trocadas. Um dos filhos herda as informações anteriores a este ponto de um dos pais e o complemento de outro pai. O outro filho herda os pedaços restantes.

mutação: é responsável pela introdução e manutenção da diversidade genética na população, alterando arbitrariamente um ou mais genes de um cromossomo escolhido aleatoriamente. Este operador fornece

meios para a introdução de novos elementos na população. A mutação assegura que a probabilidade de se chegar a qualquer ponto do espaço de busca nunca será zero, além de contornar o problema de mínimos locais, por permitir a alteração da direção de busca.

3.3. PARÂMETROS GENÉTICOS

Para a utilização de algoritmos genéticos é importante a análise dos parâmetros utilizados pois podem influir no comportamento em relação às necessidades do problema. Os principais parâmetros são:

tamanho da população: O tamanho da população afeta o desempenho global e a eficiência dos algoritmos genéticos. Com uma população pequena, o desempenho pode cair, pois a população pode cobrir apenas uma pequena parte do espaço de busca. Uma grande população geralmente fornece uma cobertura representativa do domínio do problema, além de prevenir convergências prematuras para soluções locais, em vez de globais. No entanto, para se trabalhar com grandes populações, são necessários maiores recursos computacionais, ou um tempo de execução maior;

taxa de cruzamento: é a porcentagem de indivíduos usados para o cruzamento. Quanto maior esta taxa, mais rápida a introdução de novas estruturas na população. Se esta taxa for muito alta, indivíduos com bons índices de aptidão poderão ser retirados a uma velocidade que supere a capacidade de gerar indivíduos melhores. Se esta taxa for muito baixa, a busca pode estagnar;

taxa de mutação: descreve o número de mutantes em cada iteração. Uma baixa taxa de mutação previne que uma população fique estagnada, além de possibilitar que se chegue em qualquer ponto do espaço de busca. Com um taxa muito alta, a busca se torna essencialmente aleatória;

intervalo de geração: Controla a porcentagem da população que será substituída para a próxima geração. Com um valor alto, a maior parte da população será substituída, o que pode levar à perda de indivíduos de

alto grau. Com um valor baixo, o algoritmo pode se tornar muito lento, pois o número de gerações necessárias será muito grande.

4. MATERIAIS E MÉTODOS

Programas específicos para a otimização pelos algoritmos genéticos e a classificação de imagens multiespectrais foram desenvolvidos em linguagem C++, no ambiente UNIX.

Imagens Landsat TM, com resolução espacial de 30 m, de regiões próximas às cidades de Rio de Janeiro, Florianópolis e Manaus nas bandas 5, 4 e 3 serviram de base para a análise. Como o resultado do fatiamento multiespectral é altamente dependente da distribuição das classes no espaço de cores adotado, uma comparação entre os resultados obtidos usando o espaço RGB e o espaço IHS foi efetuada.

4.1. ETAPAS

Inicialmente, para cada imagem, uma análise visual, foi efetuada com a finalidade de identificar as classes presentes. A seguir foram escolhidos pixels de treinamento para cada classe, ou seja, pixels que se sabe que pertencem a uma classe. Tentou-se, na medida do possível, manter o número de pixels por classe constante, tomando cuidado em respeitar as exigências relativas à distribuição e representatividade da amostragem (CHUVIECO).

Fixados o número de bandas (3) e o número de classes, definiu-se o tamanho da cadeia genética. Vários testes foram realizados, variando os parâmetros genéticos, como por exemplo o tamanho da população e a taxa de mutação.

A qualidade de cada indivíduo, cada solução, foi medida a partir dos pixels de treinamento. Em cada iteração, o número de pixels de treinamento corretamente classificados por cada solução foi calculado. O indivíduo recebeu como medida de qualidade (Fitness) um valor igual à taxa de pixels corretamente classificados em relação ao total de pixels de treinamento. Assim, a solução ideal teria valor 1, sendo que valores menores, entre zero e a unidade, descreveriam soluções sub-ótimas. O processo iterativo foi detido quando a qualidade do indivíduo mais apto superou um limiar fixado, ou o número de iterações ultrapassou um máximo estipulado previamente.

5. RESULTADOS

Os resultados de seis experimentos serão apresentados. Em cada um deles, um recorte das imagens foi utilizado, sendo AM1 e AM2 os recortes da imagem de Manaus, SC1 e SC2 os recortes da imagem da ilha de Florianópolis e RJ1 e RJ2 os recortes do Rio de Janeiro.

O número máximo de iterações foi fixado em 10000 e o tamanho da população em 100 indivíduos, para todos os casos. Um total de 20% da população foi mantida (elitismo). O número de mutantes é 5 para a maioria dos casos, apenas no experimento RJ2, no espaço IHS, foi usada uma taxa maior, de 8 mutantes. Os demais parâmetros genéticos utilizados em cada experimento encontram-se listados nas tabelas 1 e 2. O número de cromossomos é função do número de classes, sendo que para cada classe um total de 6 limiares são necessários.

Parâmetro	AM 1	AM 2	SC 1	SC 2	RJ 1	RJ 2
No. de classes	5	4	3	5	4	4
No. de cromossomos	30	24	18	30	24	24
Ponto de cruzamento	15	12	12	15	12	12
No. de amostras	44	40	45	50	48	41

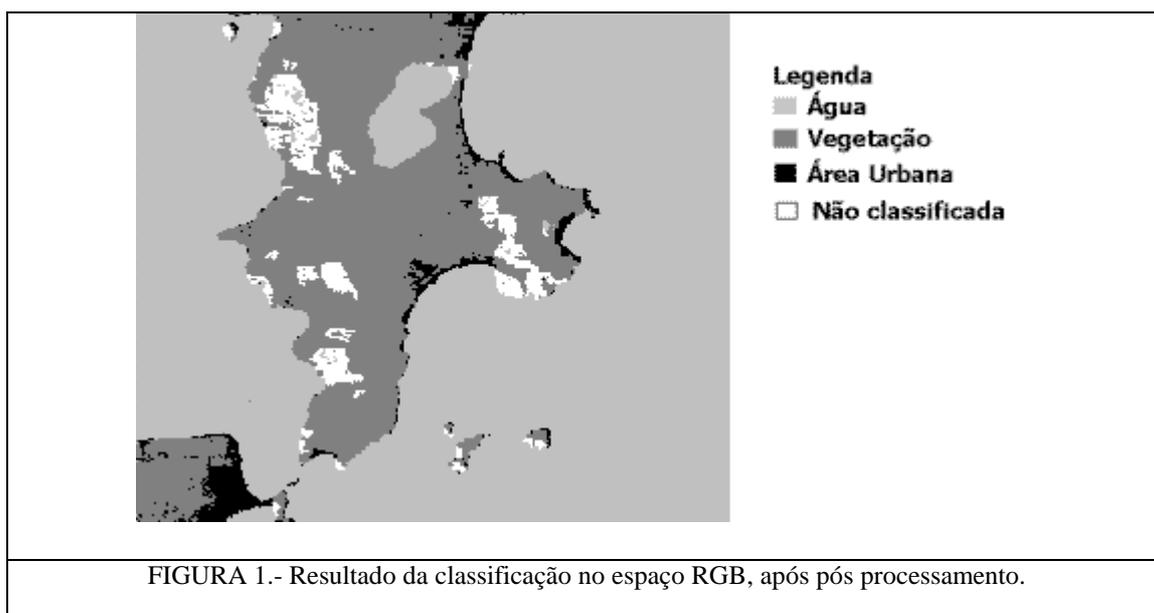
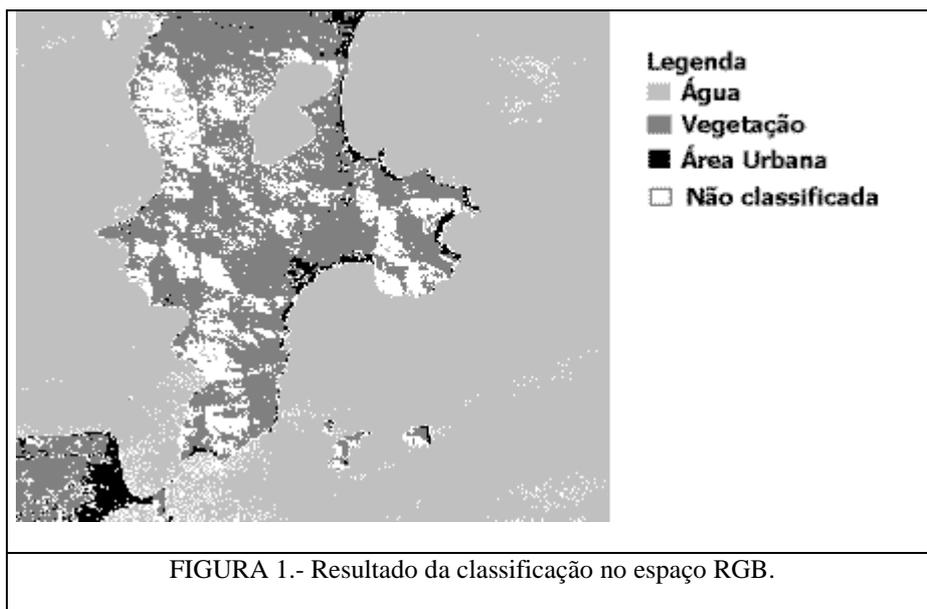
Tabela 01: Parâmetros de classificação no sistema RGB

Parâmetro	AM 1	AM 2	SC 1	SC 2	RJ 1	RJ2
No. de classes	4	5	4	5	3	5
No. de cromossomos	24	30	18	30	18	30
Ponto de cruzamento	12	15	12	15	9	15
No. de mutantes	5	5	5	5	5	8
No. de amostras	35	40	48	50	36	55

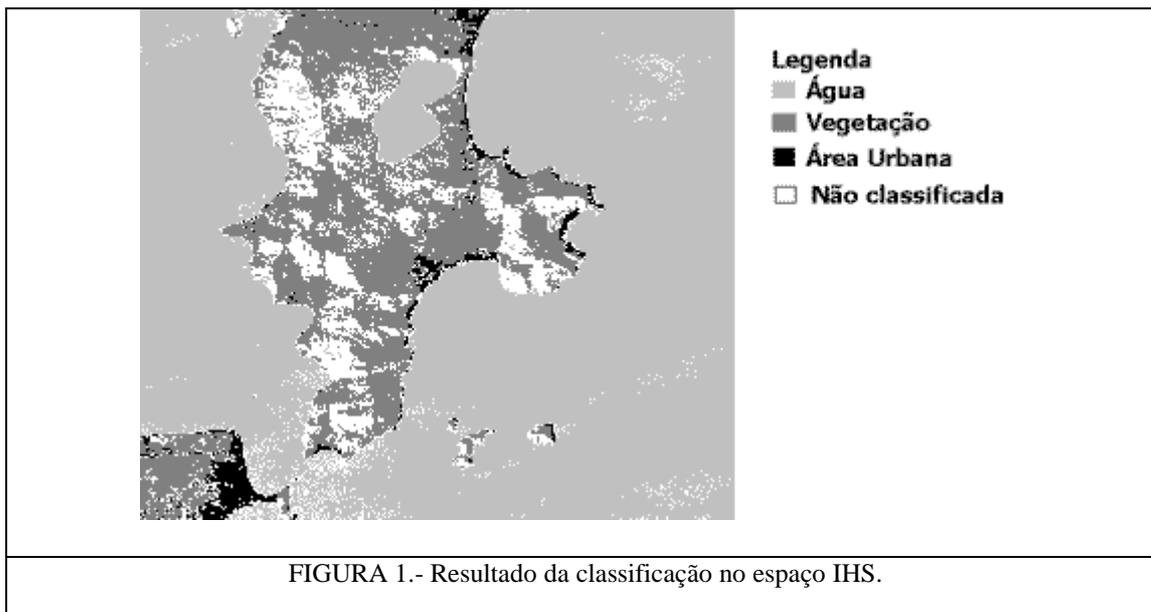
Tabela 02: Parâmetros de classificação no sistema IHS

Como exemplo será discutida em maior detalhe a imagem do experimento SC1, de Florianópolis. As classes consideradas usando o espaço RGB foram 3: área urbana, vegetação e água. Nota –se nesta imagem a presença de sombra, produzidas pelo relevo e pelo horário da tomada da imagem, que modifica a aparência de algumas regiões. Para estas 3 classes foram escolhidas 45 amostras coletadas ao longo de toda imagem como dados de entrada do programa de algoritmos genéticos.

Os resultados da classificação desta imagem no espaço RGB pode ser visto na figura 1. Como este resultado apresenta a presença de pixels isolados, uma processo de suavização, o filtro de moda, foi aplicado a este resultado, do que se obteve a imagem mostrada na figura 2.



A mesma imagem foi transformada ao espaço IHS, e um novo experimento de busca dos parâmetros ótimos foi iniciado. Neste caso, foi possível diferenciar duas tonalidades nas regiões correspondentes a vegetação, motivo este que levou a considerar 4 classes. O processo convergiu e o resultado é mostrado na figura 3.



6. CONCLUSÕES

Os testes realizados comprovaram que é possível encontrar uma estimativa dos limiares, necessário no processo de classificação pelo método dos hipercubos, usando uma abordagem baseada nos algoritmos genéticos. O processo converge para uma solução que corresponde à classificação correta, segundo os pixels de treinamento.

O número de amostras interfere diretamente no número de iterações necessárias que os algoritmos genéticos necessitam para chegar a uma solução ótima. Um número de amostras suficientemente grande fornece a informação necessária para que o algoritmo realize a busca de soluções mais rapidamente e não desperdice iterações analisando possíveis alternativas. Isto também implica em maior tempo de processamento. Por outro lado se o número de amostras for muito pequeno, irão faltar dados para o algoritmo poder fornecer uma solução adequada.

A observação dos resultados mostrou que o sistema IHS oferece uma melhor separabilidade de classes mesmo que o número de amostras seja um pouco menor que o de outros sistemas.

Os parâmetros genéticos apresentados nas tabelas 1 e 2 são aqueles que proporcionaram melhores resultados em cada caso. No entanto, diversos testes foram efetuados em cada imagem. Dentre as principais observações resultantes destes experimentos pode-se concluir que o número de mutantes não pode ser muito baixo, pois isto causa estagnação do processo de busca. Por outro lado, uma taxa muito alta faz-se que a população não consiga convergir.

O espaço de cores é determinante na performance do processo, pois a orientação das classes em relação aos eixos é um fator que influencia a separabilidade espectral. Como o espaço IHS possui a componente I ao longo da diagonal principal do sistema RGB, que é muito próxima do eixo de maior variação dos níveis de cinza numa imagem digital, é justificado que a separabilidade espectral neste espaço seja melhor e a classificação tenha melhores resultados. Isto também foi constatado no fato de poder separar melhor as duas classes de vegetação no espaço IHS, mesmo fazendo a análise visual.

Os experimentos comprovam a viabilidade do uso dos algoritmos genéticos para a solução de problemas de classificação, onde há necessidade de fixar um elevado número de parâmetros, como é o caso dos métodos dos hipercubos. Embora os experimentos tenham sido efetuados usando apenas três bandas, o método pode ser facilmente ampliado a uma dimensão maior. Uma alternativa que deve ser pesquisada é o uso desta abordagem utilizando o espaço definido pelas componentes principais, visto que neste espaço a correlação entre as bandas é mínima e com isto a performance do método de classificação pode ser melhor.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- AZEVEDO, F. M.; BRASIL, F. M.; OLIVEIRA, R.C. L. Redes Neurais com Aplicações em Controle e em Sistemas Especialistas. Florianópolis, Bookstore 2000.
- BITTENCOURT, G. 1998. Inteligência Artificial: Ferramentas e Teorias. Cap. 6. Florianópolis, Ed. Da UFSC.

BRAGA, A . P.; LUDEMIR, T. B.; CARVALHO, A .C. P. L. F. Redes Neurais Artificiais – Teoria e Aplicações. Rio de Janeiro, RJ : LTC, 2000.

CHUVIECO, E. Fundamentos de Teledetección Espacial. Madrid , Espanha : Ediciones Rialp S A, 1990.

LILLESAND, T. e KIEFER, R. Remote Sensing and Image Interpretation. Chichester : John Willey and Sons, 1994.