

O uso de algoritmos de *clustering* na mensuração da expansão urbana e detecção de alterações na Região Metropolitana de São Paulo (1991-2002)

Arlete Tieko Ohata¹
José Alberto Quintanilha¹

¹PTR/EPUSP - Universidade de São Paulo
Caixa Postal: 61 548 CEP 05508-900 – São Paulo - SP, Brasil
arlete.ohata@poli.usp.br, jaquinta@usp.br

Abstract. The objective of this work is to present a methodology to extract information from remote sensing data to identify and measure the urban growth and to detect and quantify changes occurred among land uses classes in a period of ten years. The study area includes the São Paulo Metropolitan Region (Região Metropolitana de São Paulo – RMSP) with approximately 8.000km².

Palavras-chave: remote sensing, image processing, land use, urban sprawl, change detection, processamento de imagens, uso do solo, expansão urbana, região metropolitana.

1. Introdução

A utilização de imagens de satélites permite comparar diferentes regiões e determinar tendências espaciais do desenvolvimento das cidades. Os mapas produzidos pelos pesquisadores têm importância ainda maior em se tratando da produção de informações atualizadas para subsidiar os estudos de pesquisadores em urbanismo, hidrologia, questões ambientais, energia, etc. (Schneider, 2003a). Para um acompanhamento temporal da expansão urbana, o sensoriamento remoto é um instrumento de grande valia no auxílio às pesquisas de expansão de áreas de grande extensão, como a Região Metropolitana de São Paulo, que tem aproximadamente 8.000 km², pois agrega ao estudo de áreas urbanas a possibilidade do uso de informações de abrangência regional e com boa frequência temporal

A classificação multi-espectral de imagens é uma das muitas técnicas utilizadas para extração de informações da Terra. Num modelo não-supervisionado, o processo de agrupamento de feições dentro de uma determinada classe é chamado de *clustering*.

A execução da técnica de *clustering* realiza uma importante função na identificação de algumas classes únicas, mas com extensão zonal muito pequena e que pode não ser reconhecida inicialmente pelo analista que utiliza a classificação supervisionada (Richardson et. allí, 1993) . Conseqüentemente, o método de cluster se apresenta como uma aproximação muito mais prática para a extração de informações (Viony, 2000). Os algoritmos de agrupamento mais conhecidos são o K-MEDIA e o ISODATA. Ambos tem por finalidade agruparem os pixels, dividindo os dados da imagem no espaço multiespectral, em um determinado número de classe estipulado pelo usuário (Jensen, 1996).

2. Objetivo

O objetivo principal é definir uma metodologia de detecção e mensuração da expansão urbana da RMSP, aplicando um modelo de classificação não supervisionada através do uso de algoritmos de agrupamento, destacando o K-MEDIA e o ISODATA, para o reconhecimento de padrões dos tipos de cobertura e uso do solo que estão representados na imagem orbital LANDSAT que cobre a RMSP, obtidas em duas datas 1991 e 2002.

3. Área de Estudo

Esta pesquisa tem como área de abrangência a parte da Região Metropolitana de São Paulo (RMSP) recoberta pelas imagens de satélite LANDSAT (cena 219/76). A RMSP compreende 39 municípios, correspondendo a uma superfície de 8.051 km² (EMPLASA, 1994), possuindo atualmente 17.834.664 habitantes (IBGE, 2000).

4. Material

Imagem Landsat TM 5, cena 219/76 (23/10/1991); Bandas 1,2,3,4,5,7.
Imagem Landsat ETM 7, cena 219/76 (22/04/2002); Bandas 1,2,3,4,5,7.
Software ENVI 4.0

5. Procedimentos

O trabalho foi dividido em quatro etapas:

- Definição dos parâmetros
- Análise comparativa e escolha do algoritmo
- Aplicação na área de estudo
- Análise espacial e temporal dos resultados

5.1 Definição dos parâmetros:

A escolha dos parâmetros, como visto na literatura (Yang e Lo, 2002 e Schowengerdt, 1997), foi realizada visando determinar a melhor discriminação dos alvos a serem extraídos da imagem que serão aplicados na classificação não supervisionada. Esta etapa possibilita, também, analisar o resultado da classificação em função da variação destes parâmetros. São vários os parâmetros dos algoritmos de agrupamento. Destes, os principais são: número de classes, número de iterações e limiar de mudança (*change threshold*) ou ponto de convergência.

5.1.1 Número de Classes

Segundo Yang & Lo (2002), de todos os parâmetros, o número de classes é o mais crítico, pois afeta diretamente a capacidade do algoritmo em capturar maior variedade de alvos da superfície do terreno contidos na imagem analisada. Se este número é pequeno, será gerada uma classe espectral extensa e que não retrata a diversidade das classes espectrais que ocorrem na imagem. Quanto maior este número, mais pura é a classe espectral gerada.

5.1.2 Número de Iterações

O número de iterações corresponde ao número de vezes que o algoritmo pode reagrupar ou rearranjar os dados (pixels). Este critério impede que o sistema funcione por tempo excessivo, ou entre em looping indefinido, sem alcançar o ponto inicial de convergência.

5.1.3 Limiar de mudança (*change threshold*)

O limiar de mudança (*change threshold*) é o percentual limite de pixels que podem mudar de classes durante as iterações. Este parâmetro determina a parada do processo de iteração quando o número de pixels que mudam de classes durante as iterações for menor que o percentual limite estabelecido. (ENVI, 2004)

O número de iterações e o limiar de mudança são denominados de critérios de parada, pois impedem que o algoritmo funcione indefinidamente.

5.1.4 Discussão dos Resultados

Os parâmetros dos algoritmos: número de classes, número de iterações e limiar de mudança - foram ajustados através dos testes efetuados, com os quais foi possível estudar e compreender o comportamento de cada algoritmo. Para definição dos parâmetros foi aplicado a classificação numa porção menor da imagem, variando o parâmetro número de classes em: 04, 12, 30 e 50. A classificação utilizando 50 classes, apresentou melhor discriminação e detalhamento dos alvos, permitindo que o software separasse melhor os diferentes alvos existentes na imagem.

Quanto ao parâmetro número de iterações foi especificado em 20, definido durante o acompanhamento dos processamentos. E o limiar de Mudança foi estabelecido em 5 %.

5.2 Análise comparativa e escolha do algoritmo

Esta etapa tem como objetivo analisar comparativamente o desempenho dos algoritmos de agrupamento: K-MEDIA e ISODATA, e definir a partir desta análise qual será utilizado no método a ser aplicado.

5.2.1 Característica dos algoritmos

A diferença entre o algoritmo ISODATA e o K-MEDIA, está baseada apenas no processo de inicialização:

K-MEDIA: distribuição das médias (sementes)

ISODATA: distribuição dos pixels

5.2.1.1 K-MEDIA

O K-MEDIA é um algoritmo para partição de um conjunto de elementos em determinado número de agrupamentos (clustering) K , utilizando o método dos mínimos quadrados e o ajustamento das médias (média móvel) no decorrer dos processos de iterações. O uso de um software para realizar esta operação se estrutura apenas na simples implementação de um algoritmo que se baseia nos mínimos quadrados. Este algoritmo, de forma geral, possui obrigatoriamente apenas duas etapas simples.

- A determinação dos centróides, que é a posição média de todas as amostras de um agrupamento ou classe, sendo o número de classes determinado previamente pelo usuário, em redor do qual se originará os agrupamentos (classes), funcionando os mesmos como “sementes”, e a utilização destas para a formação de novos agrupamentos.
- A associação de cada elementos a uma “semente” mais próxima.

Existem mais de 20 tipos de algoritmos descritos como algoritmos de partições K-MEDIA. Eles são conhecidos não apenas por serem os muito rápidos, como também por possuírem boas propriedades de convergência (Theiler & Gisler, 1997).

No decorrer das iterações, o programa tenta minimizar a soma dos resíduos do processo dos mínimos quadrados, sobre todos os grupos e dentro de cada grupo isoladamente em relação a distância de cada objeto para o respectivo centróide de seu grupo. A convergência é alcançada quando o resíduo da soma dos quadrados não pode mais ser reduzido. Os agrupamentos obtidos são geometricamente o mais compactos possíveis, em redor de seus respectivos centróides.

Assim, o objetivo do K-MEDIA é dividir conjuntos de elementos em K classes, da forma mais simples possível.

5.2.1.2 ISODATA (Iterative Self-Organizing Data Analysis Technique)

O método ISODATA é similar ao princípio do K-MEDIA, onde o centro dos clusters são interativamente determinados através da média móvel. O ISODATA é uma modificação do algoritmo K-MEDIA, onde é implementada a função de fusão ou divisão de classes espectrais (clusters). Apesar de ser um algoritmo similar ao K-MEDIA, o ISODATA incorpora algumas compilações heurísticas (rules-of-thumb). Existem muitas variações em torno do desenho básico deste algoritmo. As considerações aqui apresentadas foram formuladas a partir de um modelo básico, comum a todos, o qual pode ser observado em Therrien (1989), Bow (1984) ou Tou & Gonzalez (2003).

Os agrupamentos iniciais são pré-definidos pelo usuário e distribuídos ao longo do eixo diagonal do espaço atributo (feature space), que é representado por uma linha que se origina no ponto correspondente ao número máximo do nível de cinza de cada componente espectral. Se duas classes estão muito próximas e abaixo do limite estipulado, ocorrerá uma fusão das classes. Se a distância que a amostra apresenta da média das classes (centróide) for maior que a das classes existentes, esta será dividida em duas classes (Ripley, 2000). A cada iteração será recalculada a média das classes espectrais e os pixels serão reagrupados seguindo os seguintes critérios (IBGE, 2001):

- As classes com desvio padrão muito grande serão subdivididas para formar classes menores;
- Classes que estão estatisticamente muito próximas serão fundidas; e
- Classes, com número pequeno de pixels, são eliminadas.

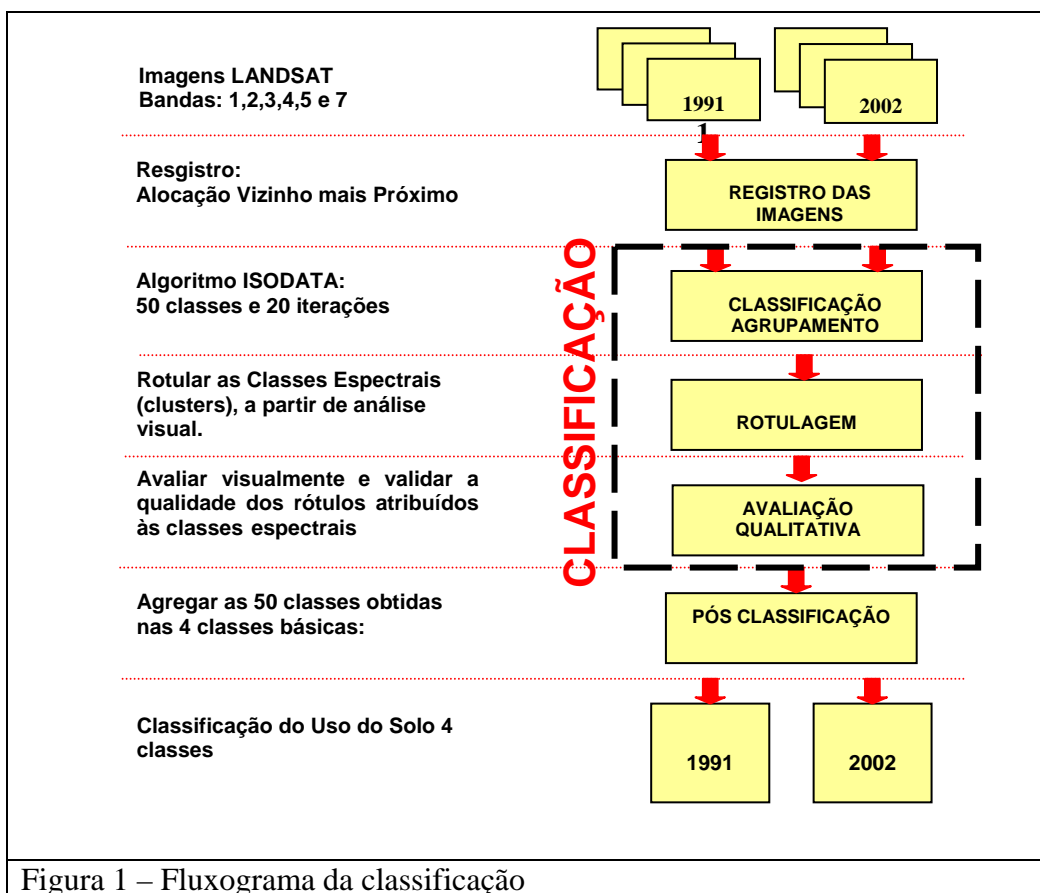
Muitos estudos investigaram o problema de como escolher aleatoriamente a posição inicial do centro dos agrupamentos e como a definição dos parâmetros propostos por ERDAS (1997) e Jensen (1996) podem influenciar o resultado final da classificação.

5.2.1.3 Discussão dos Resultados

- K-MEDIA apresenta maior confusão entre as classes, enquanto o ISODATA discrimina melhor cada alvo separando em uma classe distinta.
- Provavelmente, o recálculo dos intervalos de cada classe, através de suas médias móveis, somado a capacidade de dividir classes, juntar classes e eliminar classes menor que o limite estabelecido, favorece o ISODATA, dando-lhe uma maior flexibilidade e uma melhor discriminação dos diferentes alvos.
- No produto da classificação utilizando o K-MEDIA, existem mais classes “misturadas”, o qual sugere a necessidade de outros métodos de processamento para separar melhor as classes. O ISODATA resolve melhor estes problemas e gera uma classificação mais “limpa” na imagem bruta sem processamento anterior.
- O algoritmo ISODATA foi o que apresentou os melhores resultados na discriminação da classe urbano. Nesta classificação foi obtido uma melhor discriminação da área urbana em classes distintas.

5.3 Aplicação do método na RMSP

Com as duas etapas anteriores executadas chegou-se a definição de um método de classificação a ser aplicado na área total de estudo a Região Metropolitana de São Paulo-RMSP. Apresentado pelo fluxograma a seguir **Figura 1**.



5.3.1 Registro da Imagens

O registro foi feito Mapa versus Imagem e Imagem versus Imagem, utilizando como referência geográfica os vetores do sistema viário, limite de municípios e rede hidrográfica. Destes vetores foram obtidos os pontos de controle para a correção geométrica da imagem e georeferenciada na projeção UTM fuso 23 com referência horizontal o DATUM SAD69.

A técnica de interpolação utilizada para a correção das imagens foi o vizinho mais próximo que, segundo vários autores (Novo, 1989; Yang e Lo, 2001; Richards, 1983) não resulta em alteração dos valores originais dos pixels da imagem.

5.3.2. Classificação da Imagem

Conforme apresentado acima, a classificação não supervisionada envolve os seguintes procedimentos: classificação por agrupamento (*clustering*), rotulagem das classes espectrais (*clusters*) obtidas e avaliação qualitativa visual.

Foi aplicado o algoritmo ISODATA (ENVI, 2004) para o processo de agrupamento, conforme definido na etapa de análise comparativa e escolha do algoritmo. Os parâmetros foram aplicados, conforme o resultado da etapa de definição dos parâmetros:

- nº de classes: 50
- nº de iterações: 20
- Change Threshold: 5%.

A classificação por agrupamento foi aplicada nas Imagens LANDSAT de 1991 e 2002.

Cada classe foi sendo nomeada conforme identificada visualmente e rotulada conforme as sub-classes do Esquema de Classificação apresentado na **Tabela 1**, adaptado do esquema proposto por Anderson (1976).

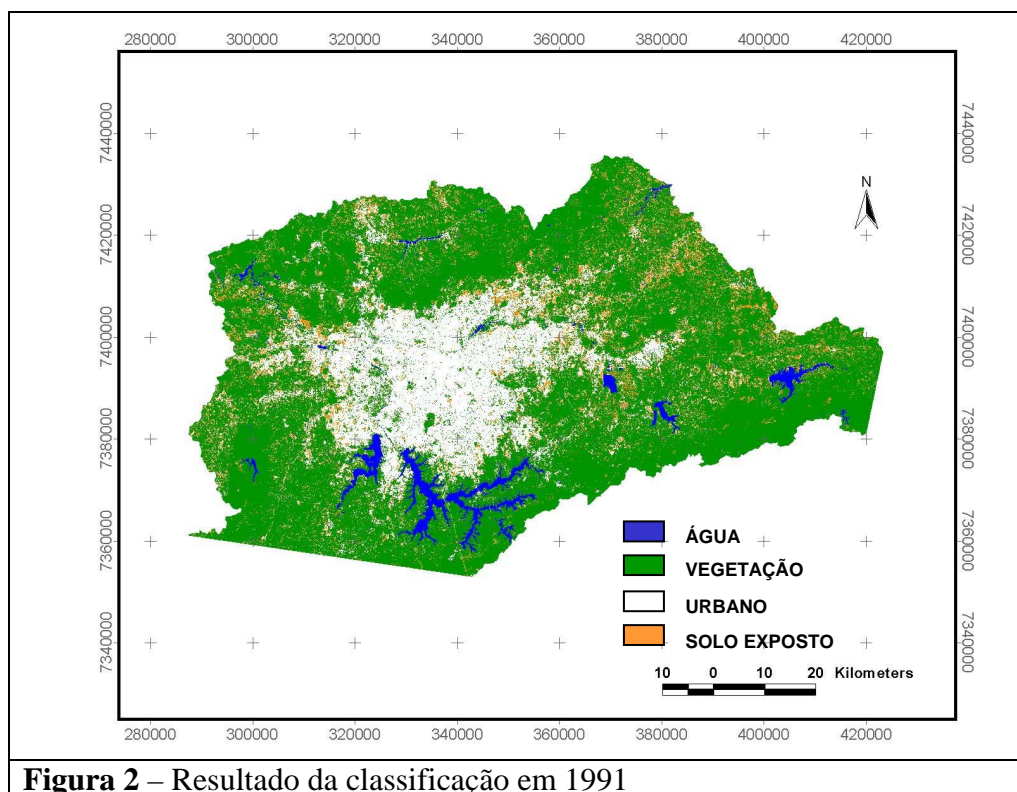
Tabela 1– Esquema de classificação - classes e sub-classes.

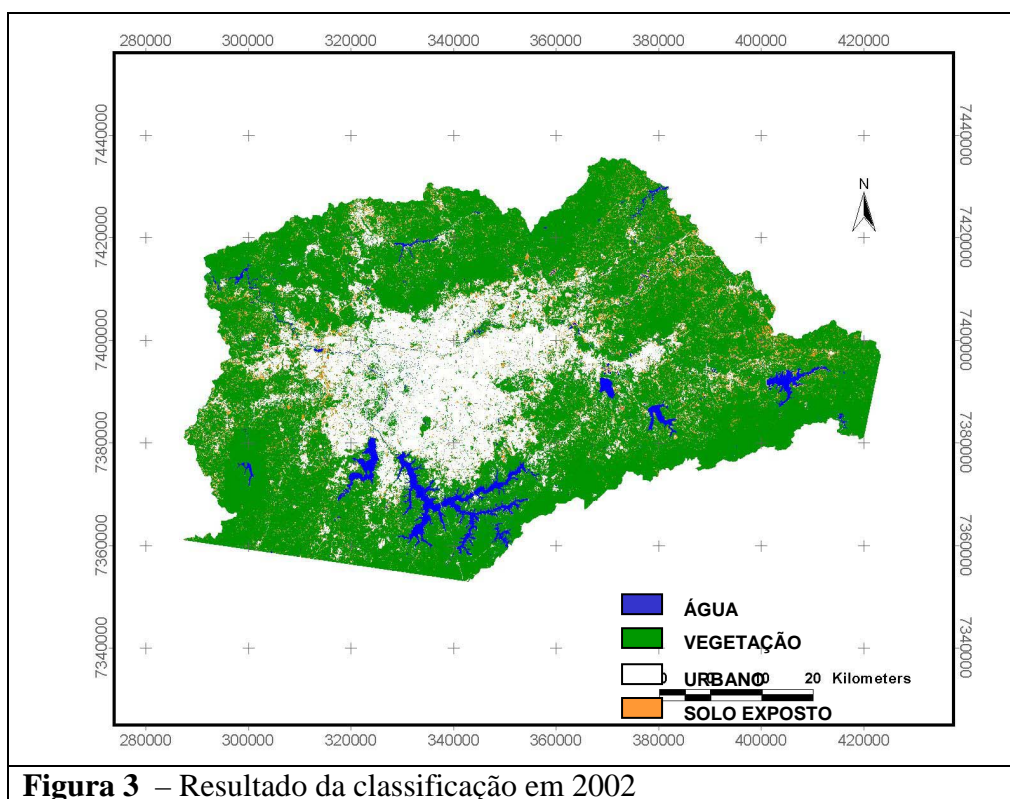
Classe - Nível I	Sub-classe - Nível II
Água	<ul style="list-style-type: none"> ➤ Represas e rios, lagoas, açudes ➤ Lagoas em área de mineração
Vegetação	<ul style="list-style-type: none"> ➤ Vegetação Sombra ➤ Vegetação Aluvional ➤ Vegetação ➤ Vegetação Baixa
Solo Exposto	<ul style="list-style-type: none"> ➤ Solo Exposto Úmido ➤ Solo Exposto ➤ Mineração de Areia
Urbano	<ul style="list-style-type: none"> ➤ Áreas construídas ➤ Sistema viário ➤ Mineração de Pedra, Cascalho

5.3.3 Pós classificação

A pós classificação é o procedimento de preparação e tratamento dos resultados das classificações para a análise espaço-temporal

A partir das classificações rotuladas de 1991 e 2002, passamos para o processo de agregação das 50 classes nas 4 classes básicas deste processo: Água, Vegetação, Solo Exposto e Urbano. Como resultado deste processo temos os mapas das duas datas, 1991 e 2002, compostos pelas 4 classes básicas. A seguir foi construída uma máscara utilizando o vetor de contorno da RMSP e aplicada sobre os mapas resultantes do processo de agregação para cada data. (Figura 2 e Figura 3).





6. Resultados

6.1 Quantificação da expansão urbana

A partir dos mapas temáticos de cobertura e uso do solo de 1991 e 2002, resultantes do processo de agregação no procedimento de pós-classificação, foi possível quantificar cada uma das 4 classes adotadas para este estudo (Vegetação, Soloexposto, Urbano e Água).

A quantidade extraída de cada classe refere-se às ocorrências internas ao limite da RMSP. Este valor foi obtido em número de pixels e convertido para área, em km².

Na **Tabela 2** temos a quantidade de pixel e a área em km² de cada uma das 4 classes extraídas das Imagens de 1991 e 2002.

Tabela 2 – Quantificação das classes para 1991 e 2002.

Classe	1991		2002	
	Nº de Pixels	Área (Km ²)	Nº de Pixels	Área (Km ²)
Água	230.844	207,7596	231.083	207,9747
Vegetação	5.247.488	4.722,7392	5.330.871	4.797,7839
Urbano	1.645.980	1.481,3820	1.856.309	1.670,6781
SoloExposto	728.285	655,4565	434.334	390,9006
Área Total	7.852.597	7.067,3373	7.852.597	7.067,3373

6.2 Detecção de mudanças

Com o cruzamento das classificações obtidas resultou na análise descrita na **Tabela 3**, que apresenta o montante de cada classe da classificação de 1991, que passou para classe urbano em 2002.

Tabela 3 – Área em pixel e em km² das classes: Solo Exposto, Vegetação, Urbano, Água em 1991 que passaram para Classe Urbano em 2002

CLASSES EM 1991	PIXEL	km ²
SOLO EXPOSTO	187.092	168,38
VEGETAÇÃO	299.091	269,18
URBANO	1.362.955	1226,66
ÁGUA	7.171	6,45
TOTAL URBANO 2002	1.856.309	1670,67

A **Figura 4** apresenta um mapa que espacializa a expansão urbana ocorrida no período de 1991 a 2002. A cor vermelha representa as áreas que passaram a ser classe urbano em 2002. É interessante observar que o crescimento apontado neste estudo ocorre em áreas periféricas de forma esparsa.

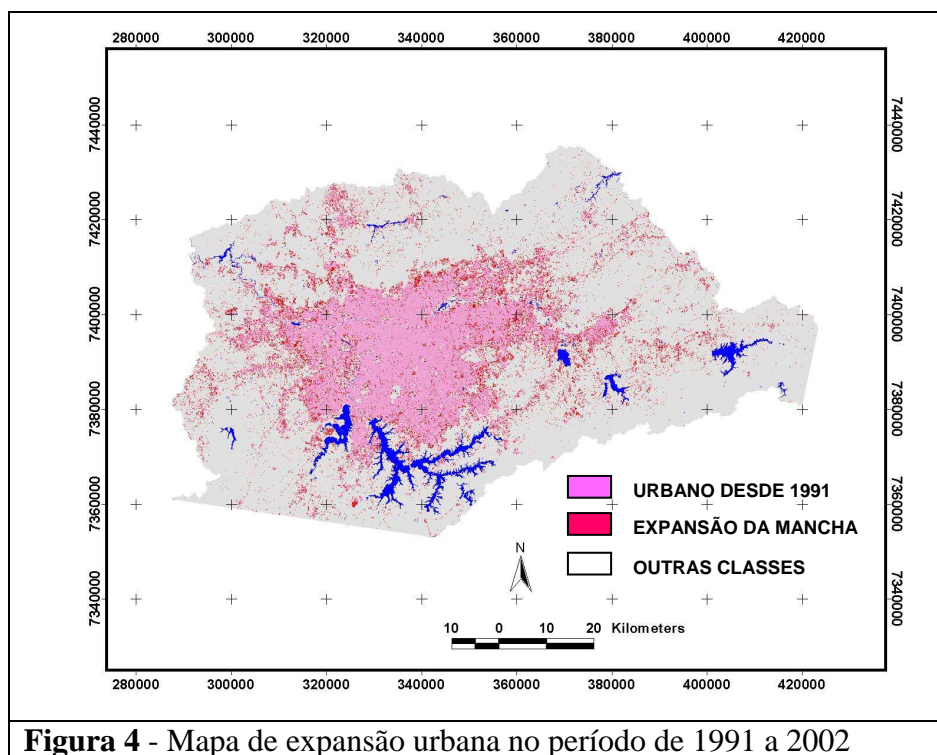


Figura 4 - Mapa de expansão urbana no período de 1991 a 2002

6. Conclusão

A metodologia aplicada atingiu o objetivo esperado na identificação, delineamento e quantificação das alterações advindas do crescimento urbano em um período de 1991 a 2002, na Região Metropolitana de São Paulo - RMSP. Com o resultado das classificações nas duas datas, foi possível quantificar as áreas ocupadas por cada classe: água, vegetação, solo exposto e urbano e detectar as alterações ocorridas no período de 11 anos decorrido entre as duas imagens. Com aplicação da metodologia chegou-se a um resultado crescimento aproximado de 12,78% da mancha urbana. Este valor é compatível à taxa de 15,5% de crescimento demográfico, dado pelos censos do IBGE de 1991 e 2000. Este crescimento se dá em função da alteração de áreas vegetadas e áreas com solo exposto para área construída.

Para este tipo de abordagem, o método de classificação por algoritmo de agrupamento se mostrou eficaz na sua aplicação. A etapa crucial que determinou a qualidade e confiabilidade do método de classificação, foi a etapa de rotulagem das classes espectrais, seguido do

processo de avaliação visual, onde a interferência humana combinada com informações da realidade de campo, é que determinou a qualidade da classificação.

Referências

- ANDERSON, J.R; HARDY, E.E.; ROACH, J. T.; WITMER, R.E. **Sistema de classificação de uso da terra e do revestimento do solo para utilização com dados de sensores remotos**. Trad de Harold Strang. Rio de Janeiro: IBGE 1979. 78p.
- BOW, S. T. **Patterns recognition**. New York: Marcel Dekker, 1984, 453 p.
- EMPLASA - Empresa Metropolitana de Planejamento da Grande São Paulo SA. **Plano Metropolitano da Grande São Paulo 1994/2010** — São Paulo: EMLASA, 1994. 285p.
- ENVI. **ENVI User's Guide**. Washington: RSI – Research System Inc. 2003. 1057 p.
- ERDAS. **ERDAS Field Guide**. Atlanta, Georgia: ERDAS, Inc. 1997.p. 225-29
- IBGE, **Introdução ao processamento digital de imagens** – Manuais Técnicos em Geociências nº 9. Rio de Janeiro: IBGE, 2001. 94p.
- IBGE – Instituto Brasileiro de Geografia e Estatística. **Estimativas da população 2001 - 2002**. Disponível em: <http://www.ibge.gov.br/> Acesso em: 26/04/2004.
- JENSEN, J. R., 1996. **Introductory Digital Image Processing--A Remote Sensing Perspective**. Prentice Hall, Inc., New Jersey, pp. 197-256.
- NOVO, E.M.L. de M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Ed. Edgar Blücher, 1989. 308p.
- RICHARDS, J. A. **Remote sensing digital image analysis, an introduction**. Berlin: Springer Verlag. 1993. 340p.
- RICHARDSON, A. J.; MENGES, R. M. and NIXON, P. R. 1985. Distinguishing weed from crop plants using video remote sensing. **Photogrammetric Engineering & Remote Sensing**, v. 51, n. 11, pp. 1785-1790.
- RIPLEY, B. D. **Pattern recognition an neural networks** 4 Ed. Cambridge: University Press. 2000. p.287- 322.
- SCHNEIDER, A.; FRIEDL, M. A.; MCLVER, D. K.; WOODCOCK, C.E. Mapping urban areas by fusing multiple sources of coarse resolution remotely sensed data. **Photogrammetry engineering and remote sensing**, v. 69, n.12 p.1377- 86. Dec. 2003.
- SCHOWENGERDT, R. A. **Remote sensing - Models and Methods for Image Processing** 2Ed. San Diego CA: Academic Press. 1997. p.389-481
- SWAIN, P. H., 1978, Fundamentals of Pattern Recognition in Remote Sensing. **In: the Remote Sensing: the Quantitative Approach**, edited by Swain, P. H. and Davis, S. M., McGraw-Hill Book Co., New York, pp. 136-187.
- THEILER, J. and GISLER, G. A contiguity-enhanced k-means clustering algorithm for unsupervised multispectral image segmentation . **Proc SPIE 3159**. pgs 108--118, 1997.
- TERRIEN, C.W. **Decision, estimation and classification**. New York: Wiley, 1989
- TOU, J. T.; GONZALEZ, R. C. **Pattern recognition principles** Massachusetts: Addison-Wesley, Reading. 1974. 603 p.
- YANG, X and LO, C.P. Using time series of satellite imagery to detect land use and land cover changes in Atlanta, Georgia metropolitan area. **International Journal of Remote Sensing**, v. 23, n. 9: p. 1775-98. 2002.
- VIOVY, N., 2000. Automatic classification of time series (ACTS): a new clustering method for remote sensing time series. **International Journal of Remote Sensing**, v. 21, n. 6, p. 1537-1560, 2000.