

Revista Brasileira de Cartografia (2016), N° 68/8: 1653-1664
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

AVALIAÇÃO DE CLASSIFICADORES DE IMAGEM DE SATÉLITE A PARTIR DO USO DE UMA TÉCNICA DE VOTAÇÃO

Satellite Image Classifiers Evaluation Using Technique of Voting

**Waldir Wagner Campos¹, Julio Gaspar², Mariana de Oliveira Lage²,
Renata Sayuri Kawashima², Mariana Abrantes Giannotti²
& José Alberto Quintanilha²**

¹Universidade de São Paulo – USP

Faculdade de Filosofia, Letras e Ciências Humanas

Departamento de Geografia – Programa de Pós-Graduação em Geografia Física

Avenida Prof. Lineu Prestes, 338, Cidade Universitária. CEP: 05508-080, Butantã, São Paulo, SP, Brasil

walwag@usp.br

²Universidade de São Paulo – USP

Escola Politécnica – Programa de Pós-Graduação em Engenharia de Transportes

Av. Prof. Luciano Gualberto, 380, Cidade Universitária. CEP: 05508-090 Butantã, São Paulo, SP, Brasil
jul.gaspar@hotmail.com; resao_sayuri@hotmail.com; {mariana_lage, mariana.giannotti, jaquinta}@usp.br

Recebido em 28 de Fevereiro, 2015/ Aceito em 2 de Fevereiro, 2016

Received on February 28, 2015/ Accepted on February 2, 2016

RESUMO

Atualmente o emprego das imagens de satélite para a identificação espacial de objetos tornou-se corriqueiro e até mesmo trivial. Devida à complexidade e o trabalho em se identificar manualmente as classes de uso e cobertura da terra, em uma determinada imagem, é comum o uso de classificadores automáticos para auxiliar esse processo de interpretação. Este artigo tem como objetivo avaliar, pela técnica de votação (“maioria simples de votos”), oito classificadores supervisionados e não supervisionados: *Spectral Angle Mapper*, *Minimum Distance*, *Isodata*, *Mahalanobis Distance*, *Binary Encoding*, *K-Means*, *Maximum Likelihood*, *Parallelepiped* para a representação de seis classes de uso e cobertura da terra (Água, Campo, Floresta, Manguezal, Urbano e Solo) em um setor da Região Metropolitana da Baixada Santista (RMBS). O uso da votação mostrou-se efetivo na classificação geral da área.

Palavras chaves: Classificação Supervisionada, Classificação Não Supervisionada, Técnica de Votação, Sensoriamento Remoto, LANDSAT.

ABSTRACT

Currently the application of satellite images for spatial identification of objects has become commonplace and even trivial. Due to the complexity and the work manually identify the classes of use and land cover in a given image, it is common to use automatic classifiers to assist this process of interpretation. This article aims to evaluate by the voting method (“majority vote”) eight supervised classifiers and unsupervised: *Parallelepiped*; *Minimum Distance*; *Mahalanobis Distance*; *Maximum Likelihood*; *Spectral Angle Mapper*; *Binary Encoding*; *Isodata* and *K-Means* for the representation of six classes of use and land cover (Water, Field, Forest, Mangrove, Urban and Dirt Soil) in a sector of the metropolitan area of Santos. The use of voting method showed was effective in the general classification of the area.

Keywords: Supervised Classification, Unsupervised Classification, Voting Method, Remote Sensing, LANDSAT.

1. INTRODUÇÃO

Recentemente uma grande quantidade de imagens de satélite tem sido disponibilizada gratuitamente, a exemplo das séries do LANDSAT fornecidas pela NASA. Isso ampliou o uso de imagens para a elaboração de mapas em grande quantidade, inclusive para o desenvolvimento de modelos dinâmicos espaciais que buscam, a partir do histórico, delinear possíveis cenários futuros. No entanto, escolher qual técnica de classificação será mais eficiente é um grande desafio. Este artigo visa avaliar o uso de técnica de votação (LAM e SUEN, 1997; XU *et al.*, 1992; LIU, *et al.*, 2014) para a escolha de um método de classificação de imagens de satélite.

Ao classificar automaticamente uma paisagem complexa, a partir de imagens de sensoriamento remoto, há o desafio de conseguir uma classificação precisa (MANANDHAR *et al.*, 2009). As classificações podem ser supervisionadas ou não-supervisionadas. Os processos supervisionados associam o espaço espectral, obtido por um sensor, com classes de cobertura da terra identificadas por um analista. As áreas identificadas são amostras dos atributos do espaço espectral, que fornecem regiões de treinamento para os parâmetros de um classificador. O classificador *Maximum Likelihood (ML)* é a técnica de classificação supervisionada mais comumente utilizada. O seu algoritmo calcula a probabilidade de um dado pixel pertencer a uma das classes, considerando como Normal ou Gaussiana a distribuição da amostra de treinamento, descrita pelo vetor de média e pela matriz de covariância do pixel (GORTE, 1999; LILLESAND *et al.*, 2004; RICHARDS, 2013a).

A aplicação de classificadores individuais, em geral, dá-se por critérios subjetivos e práticos, sendo os seus padrões de reconhecimento diretamente adotados na interpretação da imagem. No entanto, a precisão da classificação pode ser melhorada usando uma combinação de classificadores, que potencializem a tomada de decisão, ou pela seleção do classificador com melhor desempenho. O artigo aborda o desempenho dos classificadores individuais, por meio da análise da técnica de votação (maioria simples de votos) e de valores de eficiência medidos pela matriz de confusão e pela estatística Kappa (BRIEM *et al.*, 2002; LIU *et al.*, 2014).

Dois classificadores supervisionados têm como critério de decisão a distância geométrica euclidiana. O classificador *Minimum Distance* utiliza os dados das amostras de treinamento para determinar o valor médio em cada banda e o vetor de média das classes propostas pelo analista. A classificação é realizada pelo posicionamento de um pixel na classe com a média de distância mais próxima, considerando um modelo simétrico de análise entre o vetor do pixel e o espaço de atributos. A *Mahalanobis Distance* é calculada pela matriz de covariância. Os pixels são classificados considerando as menores distâncias, como no classificador de *Minimum Distance*, mas com uma medida que é sensível à direção espectral da matriz, como no classificador de *Maximum Likelihood* (GORTE, 1999; LILLESAND *et al.*, 2004; RICHARDS, 2013a).

O classificador *Parallelepiped* estabelece limites superior e inferior para os valores de brilho de cada banda. Este intervalo é definido a partir de histogramas, com níveis de cinza, dos componentes espectrais disponibilizados pelos dados de treinamento. Os pixels são classificados dentro da faixa de decisão dos limites obtidos para todas as bandas que integram a classificação (GORTE, 1999; LILLESAND *et al.*, 2004; RICHARDS, 2013a).

O *Spectral Angle Mapper* segmenta o domínio espectral com base nos ângulos dos vetores de brilho das bandas espectrais. Os limites de decisão são estabelecidos pela indicação do menor ângulo entre cada pixel e os espectros de referência das bibliotecas da imagem. Os espectros de referência são obtidos da própria imagem, por meio das amostras de treinamento (KRUSE, 1993; LILLESAND *et al.*, 2004; RICHARDS, 2013a). O Binary Encoding faz a classificação por meio de uma decisão binária. As codificações do algoritmo aplicam operações entre o vetor de um pixel e a média de todos os canais espectrais disponíveis deste pixel. A assinatura de correspondência, definida pela média do valor do brilho espectral, é obtida pelas amostras de treinamento dos dados da imagem. Os resultados alcançados são comparados por desigualdades (\geq e $<$) com 0 para definir a classe do pixel entre 0 e 1 (JIA; RICHARDS, 1993; MAZER, 1988; RICHARDS, 2013a).

Os classificadores não-supervisionados são baseados nos agrupamentos naturais dos

valores da imagem. A identidade das classes espectrais não é inicialmente conhecida e não há participação prévia do analista na indicação de amostras de classes conhecidas. Os métodos mais comuns baseiam-se no uso de algoritmos de agrupamentos (*clustering*) que procuram identificar pixels que são espectralmente similares. As medidas de similaridade mais frequentemente aplicadas são as de distância mínima ou simples (LILLESAND; KIEFER; CHIPMAN, 2004; RICHARDS, 2013b).

O método de agrupamento K-Means requer uma atribuição inicial dos vetores de medição possíveis para um número limite de grupos, especificado pelo usuário. O algoritmo, em seguida, arbitrariamente “semeia”, ou localiza, os centros dos grupos no espaço espectral. Cada pixel da imagem é então atribuído ao grupo cujo vetor médio arbitrário está mais próximo. O procedimento continua até que não haja mudanças significativas na localização da classe dos vetores médios entre as iterações (LILLESAND *et al.*, 2004; RICHARDS, 2013b).

O algoritmo *Isodata* (Iterative Self-Organizing Data Analysis) é a abordagem *K-Means* associada a verificações dos grupos formados durante ou no final do processo de agrupamento iterativo. As repetidas interações do algoritmo permitem que o número de agrupamento mude por fusão, cisão e exclusão de grupos. Diferentemente do *K-Means*, o *Isodata* não mantém um número de agrupamentos fixos e a partir do desvio padrão e da distância mínima, definidos por parâmetros pré-estabelecidos, os pixels poderão ser agrupados ou formar novos agrupamentos (LILLESAND *et al.*, 2004; RICHARDS, 2013b).

Como esses métodos de classificação usam algoritmos e abordagens diferentes, todos eles apresentam vantagens e limitações. Por esse motivo, técnicas que utilizam sistema de múltiplos classificadores, como a técnica de votação, vem sendo empregados para trazer um resultado mais acurado as classificações (MANFRÉ *et al.*, 2016).

O objetivo do artigo é demonstrar a utilidade da técnica de votação para avaliar o desempenho de oito classificadores supervisionados e não-supervisionados: *Spectral Angle Mapper* (SAM), *Minimum Distance* (MD), *Isodata* (IS), *Mahalanobis Distance* (MH), *Binary Encoding* (BE), *K-Means* (K), *Maximum Likelihood* (ML) e *Parallelepiped* (P) para a representação de seis classes de uso

e cobertura da terra (Água, Campo, Floresta, Manguezal, Urbano e Solo) em um setor da Região Metropolitana da Baixada Santista (RMBS).

2. MÁTERIAS E MÉTODOS

Os resultados obtidos seguiram um planejamento de execução. Na etapa inicial foram definidos os classificadores automáticos e a imagem de satélite analisada, em seguida, a área de estudo e as suas classes representativas. Com as classificações resultantes, foi em seguida realizada uma votação para determinar a classe dominante. Por último foi avaliado o desempenho dessa classificação obtida pela votação. Os tópicos, neste capítulo, descrevem as características técnicas e as atividades das etapas de trabalho.

2.1 Área de Estudo

A área de estudo, que compreende um setor da RMBS que abrange os municípios de Santos, Cubatão, Guarujá, Praia Grande e São Vicente (Figura 1).

Em termos gerais, esta região é composta por duas grandes unidades morfológicas, as escarpas da Serra do Mar e a planície litorânea ou costeira, de modo que as cidades se situam entre a Serra do Mar e o oceano Atlântico (SÃO PAULO, 2011).

Quanto às características da vegetação, salientam-se as presenças da Floresta Latifoliada Litorânea Perenifólia Tropical, nos depósitos arenosos das planícies litorâneas; da Floresta Latifoliada Pluvial Perenifólia Tropical e da Floresta Latifoliada Nebular Perenifólia Tropical, nas encostas e cumeadas das escarpas da Serra do Mar. Em zonas estreitas, próximas à linha de costa, a dinâmica da praia e os solos arenosos determinam a ocorrência de mosaicos com fitofisionomia herbáceo-arbustiva (OLIVEIRA-FILHO, 2009; SOUZA *et al.*, 2009).

No litoral norte de São Paulo as escarpas da Serra do Mar, mais próximas da linha de costa, condicionam a formação de manguezais somente em estreitas planícies de maré. Uma situação diferente da verificada no Complexo Estuarino-Lagunar de Cananéia-Iguape e na Baixada Santista, onde as áreas de manguezais se ampliaram associadas às planícies costeiras mais extensas e ao maior desenvolvimento da drenagem (SILVEIRA, 1952; SOUZA *et al.*, 2009).

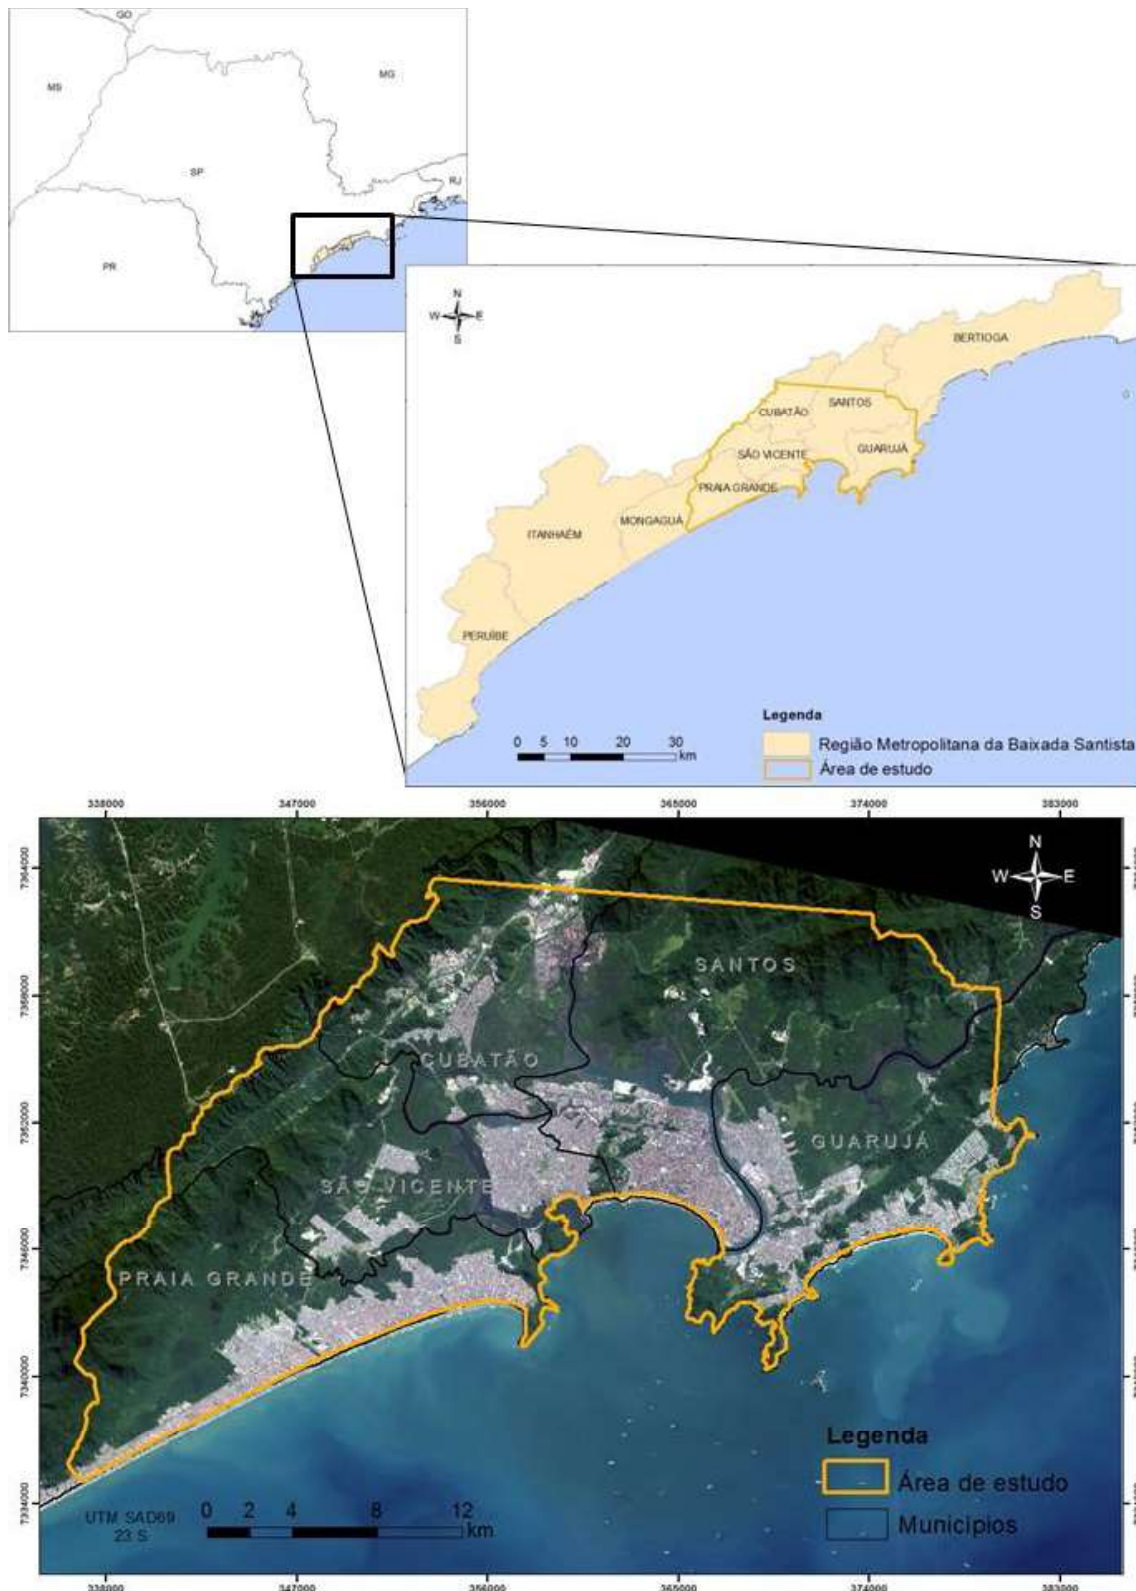


Fig. 1 – Localização da área de estudo na Região Metropolitana da Baixada Santista (RMBS).
Fonte: Google Earth (2013); Kawashima (2015).

A associação de fatores histórico-geográficos estabeleceu as bases estruturais responsáveis pelo intenso crescimento econômico regional. Destacam-se os municípios de Santos e São Vicente, constituindo uma metrópole regional que abriga um parque industrial próprio, comércio

desenvolvido e o porto de Santos, o de maior volume de importação e exportação de cargas com alto valor agregado (CAMPOS, 2009).

A antiga colonização da baixada e do arquipélago santista vicentino associada à proximidade com a Região Metropolitana de São

Paulo (RMSP), proporcionaram a implantação de uma economia complementar e dependente em alguns setores. Tais como as indústrias de base em Cubatão e as atividades comerciais e imobiliárias induzidas pelo turismo em Praia Grande e no Guarujá, onde são comuns os repentinos crescimentos populacionais nos fins de semana e feriados prolongados; tratam-se das primeiras áreas atingidas pelo processo de

loteamento voltado para segunda residência (CAMPOS, 2009).

2.2 Procedimentos

A intenção do artigo é avaliar os classificadores de imagem de satélite a partir do uso de uma técnica de votação, a síntese dos processos envolvidos para alcançar esse objetivo é demonstrada na Figura 2.

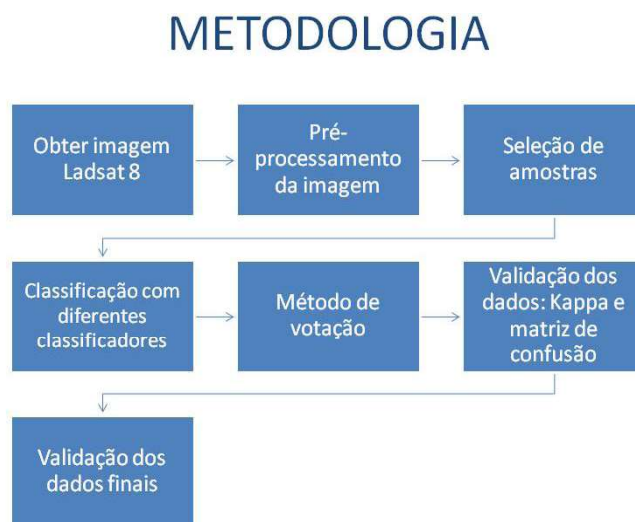


Fig. 2 – Síntese das etapas dos procedimentos para a realização do artigo. Fonte: Autores.

As etapas iniciais do desenvolvimento do trabalho foram direcionadas à obtenção e pré-processamento de uma cena do satélite LANDSAT 8, que opera com os sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS), fornecendo onze bandas espectrais (Tabela 1).

Para a realização do trabalho foi selecionada uma cena (órbita 219 e ponto 77) de 13/01/2013, disponível no *site* (<http://earthexplorer.usgs.gov/>) do Departamento de Serviço Geológico dos Estados Unidos (USGS), e as bandas 2, 3, 4, 5 e 6 (Tabela 1).

Tabela 1: Descrição das bandas do LANDSAT 8

Descrição das bandas (resolução de 30 m)	Comprimento de onda (µm)	Resolução espacial (m)
Banda 1 – azul	0,43–0,45	30
Banda 2 – azul	0,45–0,51	30
Banda 3 – verde	0,53–0,59	30
Banda 4 – vermelho	0,64–0,67	30
Banda 5 – infravermelho próximo	0,85–0,88	30
Banda 6 – infravermelho ondas curtas	1,57–1,65	30
Banda 7 – infravermelho ondas curtas	2,11–2,29	30
Banda 8 – pancromática (15 m)	0,50–0,68	15
Banda 9 – cirrus (nuvens)	1,36–1,38	30
Banda 10 – infravermelho termal (100 m)	10,60–11,19	100
Banda 11 – infravermelho termal (100 m)	11,50–12,51	100

Fonte: Poursanidis, *et al.* (2015); Roy (2014); NASA (2015).

Foi realizada uma etapa de pré-processamento na imagem fazendo a georreferência para o sistema de projeção UTM Fuso 23S e datum SAD 69, sendo em seguida cortada para conter a área de estudo. Tal procedimento permitiu reduzir o tempo de processamento e facilitou a comparação dos resultados gerados. Em função das características de uso e cobertura da terra, na área de estudo, definiram-se seis classes de análise: Água, Campo, Floresta, Manguezal, Urbano e Solo (KAWASHIMA *et al.*, 2015; BRIEM, *et al.*, 2002; BOSSARD *et al.*, 2000).

No aplicativo ENVI[®] foram selecionados sete classificadores supervisionados baseados em pixel: *Parallelepiped* (P), *Minimum Distance* (MD), *Mahalanobis Distance* (MH), *Maximum Likelihood* (ML), *Spectral Angle Mapper* (SAM) e *Binary Encoding* (BE); e dois não-supervisionados baseados em pixel: *Isodata* (IS) e *K-Means* (K) (BRIEM, *et al.*, 2002; GORTE, 1999; ROY, 2014).

Utilizaram-se amostras de treinamento, que são os pixels representativos de cada uma das 6 classes, devidamente rotulados e separados, que retratam o uso e cobertura da terra da área de estudo. Os parâmetros definidos pelo programa para cada classificador foram mantidos, já que a finalidade era analisar o resultado direto das classificações com a menor influência do usuário. As imagens resultantes da classificação foram padronizadas em um mesmo sistema de cores e visualmente comparadas (BRIEM, *et al.*, 2002; GORTE, 1999; ROY, 2014).

A técnica da maioria simples de votos (regra dos votos) foi selecionada para avaliar o desempenho dos classificadores, ou seja, um pixel é efetivamente atribuído à classe que a sua probabilidade de pertinência seja maior na maioria dos classificadores utilizados. Como o seu uso é fácil, tem sido amplamente aplicado em classificações práticas e tem provado ser uma estratégia efetiva. Devido ao seu princípio básico de determinar as classes pelo resultado da maioria simples de votos, prevalece a classe mais recorrente entre os vários classificadores utilizados. A decisão da classe de cada pixel é verificada mais de uma vez, o que ajuda na decisão da classe final e diminui a probabilidade

de erro devido a um limite no classificador (LIU *et al.*, 2014).

A análise comparada de classificadores pode melhorar os resultados de reconhecimento dos alvos, e isso independentemente dos classificadores serem supervisionados ou não-supervisionados (LEE, 1995).

O método da técnica de votação assume que os classificadores são implantados, e que, para cada amostra de entrada, cada classificador produz uma decisão única sobre a identidade da amostra. Ao combinar as decisões dos classificadores, a amostra é atribuída à classe para a qual há um consenso, ou quando pelo menos a maioria dos classificadores estão de acordo sobre a identidade. Caso contrário, a amostra é rejeitada. Para o problema que estamos examinando, há apenas uma resposta correta (XU *et al.*, 1992).

Foram selecionados 1141 pontos de controle aleatórios (“verdade observada”) na imagem. Estes foram obtidos de forma visual, interpretando o comportamento do alvo na imagem de satélite. Eles foram usados como parâmetros de referência para o acerto ou erro do classificador. As classes identificadas nos pontos de controle e representadas nas imagens classificadas foram tabuladas no Excel[®], montando-se uma tabela para comparar os resultados obtidos pelos pontos de controle (pixel) em cada classificação. Fixaram-se os resultados obtidos em cada pixel para comparação, considerando a classe diretamente observada (acerto) e aquela obtida pelo classificador (Tabela 2).

Após a verificação de acerto e erro por cada classificador, somamos os acertos por classe. Considerou-se o número de acertos dos classificadores somado ao valor de referência dos pontos observados para a definição de uma classe de uso e cobertura da terra (Tabela 3). Em 98 pixels, aproximadamente 8,6% do total analisado, não se obteve uma classe direta havendo uma divisão da classificação do pixel em duas ou três classes (Tabela 4). Adotou-se, em tais ocorrências, um sorteio como critério de inclusão, em que, a primeira classe verificada foi considerada automaticamente como a verdadeira.

Tabela 2: Modelo com os 1141 pontos amostrados da tabela de análise de erro e acerto dos classificadores selecionados

Pontos de Controle	Observado	IS	K	BE	ML	MH
0	Água	Água	Água	Água	Água	Água
1	Água	Água	Água	Água	Água	Água
2	Água	Água	Água	Água	Água	Água
200	Campo	Campo	Urbano	Campo	Campo	Campo
201	Campo	Campo	Floresta	Campo	Campo	Campo
384	Floresta	Floresta	Campo	Floresta	Floresta	Floresta
385	Floresta	Floresta	Campo	Manguezal	Floresta	Floresta
583	Manguezal	Floresta	Campo	Floresta	Manguezal	Manguezal

Tabela 3: Modelo simplificado da tabela de quantificação de erros e acertos das classes de uso e cobertura da terra

Pontos de controle	Água	Campo	Floresta	Manguezal	Urbano	Solo	Classe
0	9	0	0	0	0	0	Água
1	8	1	0	0	0	0	Água
2	9	0	0	0	0	0	Água
200	0	7	1	0	1	0	Campo
201	0	6	3	0	0	0	Campo
384	0	1	6	2	0	0	Floresta
385	1	1	4	1	1	1	Floresta
583	0	2	2	5	0	0	Manguezal

Tabela 4: Número de pixels sem classe direta por classificador analisado

Classificador	Número de pixels sem classe direta
<i>Spectral Angle Mapper</i> (SAM)	5
<i>Minimum Distance</i> (MD)	0
<i>Isodata</i> (IS)	80
<i>Mahalanobis Distance</i> (MH)	3
<i>Binary Encoding</i> (BE)	0
<i>K-Means</i> (K)	3
<i>Maximum Likelihood</i> (ML)	3
<i>Parallelepiped</i> (P)	4
Total	98

Essa estratégia foi adotada, uma vez que, o objetivo é avaliar o desempenho de diferentes classificadores pela técnica de votação em condições controladas. Essa tomada de decisão poderia considerar características particulares da paisagem para a gestão de áreas protegidas. Nesta condição a prioridade seria das classes de

vegetação (Manguezal e Floresta) sobre as outras classes definidas (Água, Campo, Solo e Urbano), com menor risco para o gestor.

A matriz de confusão (Tabela 5) mostrou a porcentagem de acertos dos classificadores por classe de uso e cobertura da terra, que forneceram a base para o cálculo do Índice Kappa. Os

valores obtidos embasaram a comparação do desempenho dos classificadores individuais com a técnica de votação, considerando as classes específicas, a eficiência geral da classificação

da imagem por classificador e adaptações na técnica da votação com diferentes combinações de classificadores segundo o Índice Kappa (LIU, et al., 2014).

Tabela 5: Exemplo de matriz de confusão gerada para o SAM

Classe	Água	Campo	Floresta	Manguezal	Urbano	Solo	Total por pontos observados
Água	199	0	0	1	0	0	200
Campo	1	90	45	19	9	9	184
Floresta	0	12	113	56	0	0	199
Manguezal	0	0	6	183	0	0	197
Urbano	23	10	21	49	24	24	169
Solo	7	4	2	2	139	139	192
Total por classificador	230	116	187	310	126	172	1141

RESULTADOS E DISCUSSÕES

A Figura 3 apresenta os oito imagens temáticas geradas por cada classificador. É possível perceber também que o desempenho do Isodata e do K-Means é diferente em relação aos outros classificadores, havendo muitas classes apontadas de forma incorreta, como facilmente pode ser observado nos setores urbanizados e na faixa oceânica (confusões entre Água e Campo; Água e Floresta; Mangue e Urbano; Solo e Floresta).

O resultado (TABELA 6) da comparação entre os pontos observados (validação) e a classificação alcançada pelos classificadores individuais destaca a classe água como a de melhor índice geral de acertos, com uma média de 97,56%. As classes Manguezal e Solo, respectivamente com médias de 46,07 e 12,75%, obtiveram as piores taxas de acertos por classificador. Entretanto é importante ponderar tais análises também por classe e classificador individuais. Desta forma, o classificador com melhor desempenho para a classe Campo é o *Parallelepiped* (88,59%), para a Floresta o *Maximum Likelihood* (93,97%), para o Manguezal o *Spectral Angle Mapper* (92,89%), para o Urbano e o Solo a *Maximum Likelihood* (88,02 e 32,49). Já o classificador com pior desempenho para a classe Campo e Urbano é o *K-Means* (33,15 e 0%) e para a Floresta o *Parallelepiped* (7,04%). A classe Água otbteve um ótimo desempenho em todos

os classificadores.

Chama a atenção os índices, generalizadamente baixos (TABELA 6), relacionados à classe Campo e a alternância verificada para o Manguezal, em que, *Binary Encoding* (6,09%), *Isodata* (0%), *K-Means* (0%) e *Parallelepiped* (0%) apresentaram um desempenho nulo ou insuficiente, entretanto, o *Maximum Likelihood* (89,34%), a *Mahalanobis Distance* (89,34%), a *Minimum Distance* (90,86%) e o *Spectral Angle Mapper* (92,89) tiveram um desempenho, mesmo considerando o número global de acertos entre todos os classificadores e classes, muito elevado.

Analisando especificamente a média geral dos classificadores, é possível propor a seguinte ordem de desempenho, considerando as maiores taxas de acertos a partir de 60%: *Spectral Angle Mapper*, *Minimum Distance*, *Mahalanobis Distance* e *Maximum Likelihood*.

A estatística Kappa pode ser definida como uma medida de associação usada para descrever e testar o grau de confiabilidade e precisão na classificação (IWAI; QUINTANILHA, 2005; PERROCA; GAIDZINSKI, 2003; KOTZ, 1983). Por isso esse coeficiente é um bom método para fazer avaliações comparadas de diferentes classificadores (LIU et al., 2014). As matrizes para calcular o Kappa foram elaboradas a partir de tabelas transpostas de classificação *versus* a realidade, como apresentado por Congalton e Mead (1983):

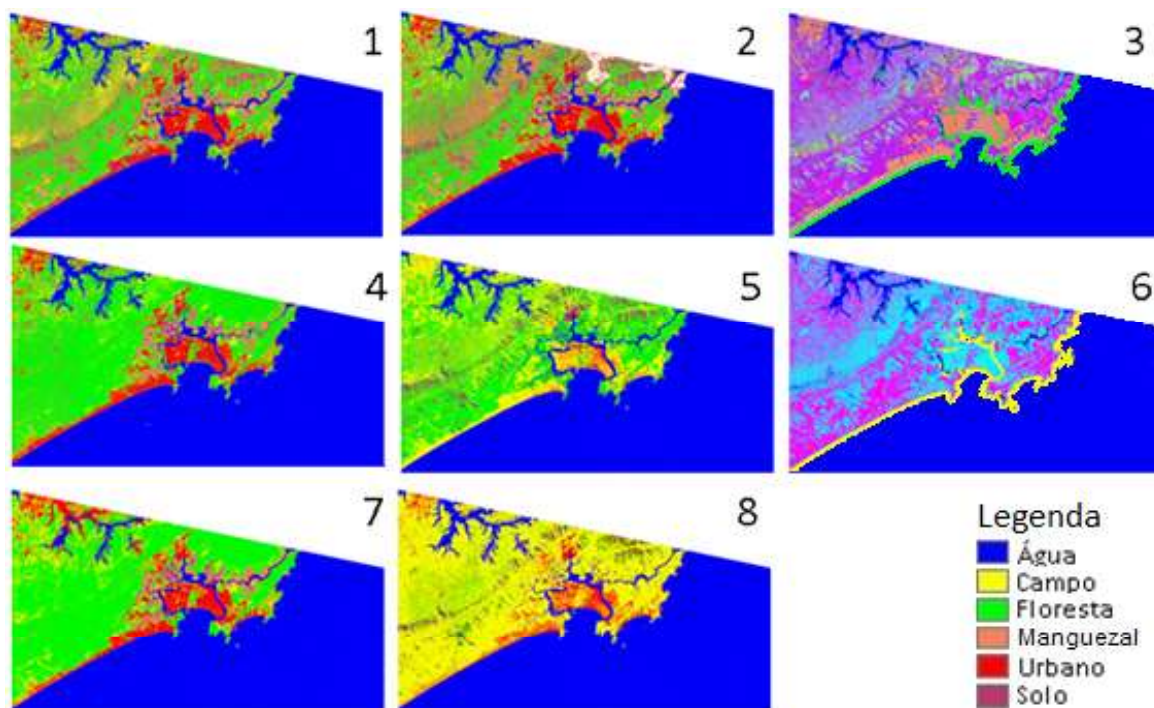


Fig. 3 - Classificadores: 1. *Spectral Angle Mapper* (SAM); 2. *Minimum Distance* (MD) 3. *Isodata* (IS); 4. *Mahalanobis Distance* (MH); 5. *Binary Encoding* (BE); 6. *K-Means* (K); 7. *Maximum Likelihood* (ML); 8. *Parallelepiped* (P).

Tabela 6: Taxa (%) de acerto dos classificadores individuais analisados

Classe	SAM	MD	IS	MH	BE	K	ML	P	MÉDIA
Água	99,50	99,50	98,50	85,50	99,50	99,50	99,00	99,50	97,56
Campo	48,91	35,87	40,76	45,65	73,91	33,15	74,46	88,59	55,16
Floresta	56,78	51,26	27,14	89,45	68,34	46,73	93,97	7,04	55,09
Manguezal	92,89	90,86	0,00	89,34	6,09	0,00	89,34	0,00	46,07
Urbano	72,40	85,94	72,40	81,25	20,83	0,00	88,02	57,29	59,77
Solo	20,81	21,83	0,00	21,83	0,00	0,00	32,49	5,08	12,75
Média	65,22	64,21	39,80	68,84	44,78	29,90	79,55	42,91	

Na Figura 4 podemos ver as estatísticas Kappa dos classificadores com melhor desempenho (taxa de acertos acima de 60% da Tabela 6), e duas formas de votação: uma com todos os classificadores (Votação 1) e outra apenas com os melhores classificadores (Votação 2). O intuito dessa segunda é mostrar o resultado mais perto

da realidade, removendo o erro devido ao uso de classificadores não adequados. A porcentagem média de acerto da Votação 1 foi de 79% e Kappa de 75%, enquanto da Votação 2 a média de acerto foi de 77% e Kappa de 75%. Verificando-se os valores de referência de Índice Kappa destaca-se como o melhor o *Maximum Likelihood* (ML).




Fig 4 - Comparativo da estatística Kappa entre os melhores classificadores.

4. CONCLUSÕES

Os classificadores individuais com melhor desempenho foram o *Spectral Angle Mapper* (SAM), o *Mahalanobis Distance* (MH), o *Maximum Likelihood* (ML) e o *Minimum Distance* (MD). O sistema de votação não se mostrou efetivo, pois a porcentagem média de acertos (54,4%) e o resultado do Índice Kappa (75%) ficaram abaixo do melhor classificador empregado – o *Maximum Likelihood* (ML) (79,5% e 78%, respectivamente).

A literatura especializada (LIU, et al., 2014) ressaltou que a técnica da votação incrementou o desempenho geral da classificação de imagens, com repercussões diretas de aumento na porcentagem média de acertos e no resultado do Índice Kappa.

Para os gestores de Unidades de Conservação (UC), na RMBS, preocupados com a análise e o monitoramento dos manguezais e florestas devem ser utilizados diferentes classificadores. O *Spectral Angle Mapper* tem o melhor desempenho para a classe Manguezal e o *Maximum Likelihood* para a classe Floresta.

No caso, todos os classificadores utilizados assumem que cada pixel pertence a uma só classe e que não existem pixels no classificador. Uma próxima etapa será aplicar uma metodologia utilizando classificadores fuzzy e de redes neurais, onde há a possibilidade de um mesmo pixel pertencer a diferentes classes com diferentes possibilidades.

AGRADECIMENTOS

Os Autores agradecem ao Programa de Pós Graduação em Engenharia de Transportes da Escola Politécnica da Universidade de São Paulo pela oportunidade da pesquisa, ao doutorando Luiz Augusto Manfré pelo suporte no uso da técnica de votação, ao Laboratório de Geoprocessamento da EPUSP e à EPUSP pela disponibilização da infraestrutura e o Conselho Nacional de Pesquisa (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal Nível Superior (CAPES) pelas bolsas concedidas.

REFERÊNCIAS BIBLIOGRÁFICAS

BRIEM, G. J., BENEDIKTSSON, J. A., SVEINSSON, J. R. Multiple classifiers applied to multisource remote sensing data. **IEEE**

Transactions on Geoscience and Remote Sensing, 40 (10), 2002, 2291-2299.

BOSSARD, M.; FERANEC, J.; OTAHEL, J. “**CORINE land cover technical guide**”. Addendum 2000. Technical report 40, 2000. 105p. EEA. Accessed November 9, 2014. <http://www.eea.europa.eu/publications/tech40add>.

CAMPOS, W. W. **Análise geocológica e paisagística dos ecossistemas costeiros da ilha comprida, no Complexo Estuarino-lagunar de Iguape-Cananéia – SP**. São Paulo, 2009. 280 f. Trabalho de Graduação Individual (Geografia) – Faculdade de Filosofia Letras e Ciências Humanas, Universidade de São Paulo. 2009.

GALVÃO, W. S.; MENESES, P. R. Uso de SIG e do classificador ISODATA na geração do mapa de regiões geoambientais homogêneas na bacia do rio São Francisco, como um produto estratégico de apoio às ações de planejamento de redes fluviométricas. In: XII Simpósio Brasileiro de Sensoriamento Remoto, 2005, Goiânia. **Anais**. Goiânia, Brasil, 16-21 2005, INPE, p. 2177-2184.

GOOGLE EARTH: **catálogo de imagens disponibilizado pelo programa**. Acessado em: jul./ago. 2013. Escala aproximada de visualização: 1:5.000.

GORTE, B. Supervised image classification. In: STEIN, A.; VAN DER MEER, F.; GORTE, B (EE.). **Spatial statistics for remote sensing**, Dordrecht, NLD: Kluwer Academic Publishers, 1999. p. 153-163.

HILBERT, K. W. Land Cover Change within the Grand Bay National Estuarine Research Reserve: 1974-2001. **Journal of Coastal Research**, v. 22, n 6, 2006, p. 1552-1557.

IWAI, O. K., QUINTANILHA, J. A. Utilização de imagens de satélite como ferramenta de auxílio ao planejamento urbano. **Revista de Geografia Norte Grande**, 34, 2005. 65-82pp.

Instituto Brasileiro de Geografia e Estatística - IBGE. **Introdução ao processamento digital de imagens**. Rio de Janeiro, IBGE: 2000. (Série Manuais Técnicos em Geociências, 9). 91p.

ITT Visual Information Solutions. **ENVI User's Guide**. ENVI Version 4.7. Edição de Agosto de 2009. 200p.

- JENSEN, J. R. **Sensoriamento remoto do ambiente uma perspectiva em recursos terrestres**. São José dos Campos: Editora Parêntese, 2009. 598 p.
- JIA, X.; RICHARDS, A. Binary Coding of Imaging Spectrometer Data for Fast Spectral Matching and Classification. **Remote Sensing of Environment**, New York, NY, USA, v. 43, n. 1, p. 47-53, Jan. 1993.
- KAWASHIMA, R. S. **Modelagem da dinâmica espacial das mudanças na cobertura da terra na região da Baixada Santista**. São Paulo, 2015. Dissertação (Engenharia de Transportes) – Escola Politécnica, Universidade de São Paulo. 2015. 192 f.
- KAWASHIMA, R. S., DE ALMEIDA, C. M., GIANNOTTI, M. A., QUINTANILHA, J. A. Análise das mudanças temporais de cobertura da terra na região portuária da Baixada Santista-SP e a proposição de modelos de dinâmica espacial, **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE. 1082-1089pp.
- KOTZ, S. & JOHNSON, N. L. **Encyclopedia of statistical sciences**. New York: John Wiley & Sons; 1983. v.4, p.352-4.
- KRUSE, F. A., LEFKOFF, A. B., BOARDMAN, J. W., HEIDEBRECHT, K. B., SHAPIRO, A. T., BARLOON, P. J., GOETZ, A. F. H. The spectral image processing system (SIPS) interactive visualization and analysis of imaging Spectrometer Data. **Remote Sensing Environmental**, New York, NY, USA, v. 44, n. 2-3, p. 145-163, Oct. 1993.
- LAM, L; SUEN, C.Y. Application of Majority Voting to Pattern Recognition: Na Analysis of Its Behavior and Performance. **IEEE Transactions on Systems, Man and Cybernetics** – Part A, vol. 27 n° 5, Setember 1997.
- LANGE, A. Accuracy Specifications Affect Application Success. **GIS World**, v.10, n. 10, 1997, p. 32.
- LEE, D.S. **A theory of classifier combination: The neural network approach**. Ph.DDissertation, State Univ. New York, Buffalo, 1995. 146p.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Digital image interpretation and analysis. In: LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 5 ed. Danvers: John Wiley & Sons In., 2004. p. 491-637.
- LU, D.; MAUSEL, P.; BROZNDÍZIO, E.; MORAN, E. Change detection techniques. International. **Journal of Remote Sensing**, v. 25, n. 12, 2004 p.2365–2407.
- LIU, J.; PAN, Y.; ZHU, X.; ZHU, W. Using phenological metric and the multiple classifier fusion method to map land cover types. **Journal of Applied Remote Sensing**, v.8, 2014.
- MAZER, A. S., MARTIN, M., LEE, M., & SOLOMON, J. E. Image processing software for imaging spectrometry data analysis. **Remote Sensing of Environment**, New York, NY, USA, v. 24, n. 1 p. 201-210, Feb. 1988.
- MANANDHAR, R., ODEH, I. O. A., ANCEV, T. Improving the accuracy of land use and land cover classification of Landsat data using post-classification enhancement. **Remote Sensing**, Sydney (AUT):MDPI, n.1, p. 330-344, Jul. 2009.
- MANFRÉ, L. A., DE ALBUQUERQUE NÓBREGA, R. A., QUINTANILHA, J. A. Evaluation of Multiple Classifier Systems for Landslide Identification in LANDSAT Thematic Mapper (TM) Images. **ISPRS International Journal of Geo-Information**, 2016, 5(9), p. 164.
- NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 3ª ed. São Paulo: Ed Blucher, 2008, p. 363.
- OLIVEIRA-FILHO, A. T. Classificação das fitofisionomias da América do Sul cisandina tropical e subtropical: proposta de um novo sistema – prático e flexível – ou uma injeção a mais de caos? **Rodriguésia**, v. 60, n. 2, p. 237-258, mar. 2009.
- ALMEIDA, T., MENESES, P., ROSA, A., SANO, E., SOUZA, E., BAPTISTA, G., BRITES, R. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília, DF: Universidade de Brasília–CNPq. 2012. 266p.
- NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). LANDSAT science. **LANDSAT 8**. Disponível em < http://

- landsat.gsfc.nasa.gov/?page_id=5377>. Acesso em: 16 Out. de 2015.
- PERROCA, M. G.; GAIDZINSKI, R. R. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes: coeficiente Kappa. **Revista da Escola Enfermagem da USP**, v. 37, n. 1, p. 72-80, 2003.
- POURSANIDIS, D., CHRYSOULAKIS, N., & MITRAKA, Z. Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urban land cover mapping. **International Journal of Applied Earth Observation and Geoinformation**, 35, 2015. 259-269.
- RICHARDS, J. A. Supervised classification techniques. In: RICHARDS, J. A. **Remote sensing digital image analysis: an introduction**. 5 ed. Berlin: Springer-Verlag, 2013a. p. 247-318.
- RICHARDS, J. A. Clustering and unsupervised classification. In: RICHARDS, J. A. **Remote sensing digital image analysis: an introduction**. 5 ed. Berlin: Springer-Verlag, 2013b. p. 319-341.
- ROY, D. P. Landsat-8: science and product vision for terrestrial global change research. **Remote Sensing of Environment**, Philadelphia, USA: Elsevier, v. 145, 2014, p. 154-172.
- SÃO PAULO (Estado). Secretaria de Planejamento e Desenvolvimento Regional. **Caracterização socioeconômica de São Paulo: Região Metropolitana da Baixada Santista**. São Paulo, 2011.
- SILVEIRA, J. D. Baixadas litorâneas quentes e úmidas. São Paulo: Faculdade de Filosofia, Ciências e Letras da Universidade de São Paulo (FFCL – USP), 1952. (**Geografia**, 8).
- SOUZA, C. R. de G.; LOPES, E. A.; LUNA, G. da C. Coastal plain and low-medium slope sub-biomes: a new approach based on studies developed in Bertioga (SP). **Brazilian Journal of Ecology**, v. 8, n. 1/2, p. 29-39. 2009.
- TOU, J. T.; GONZALEZ, R. C. **Pattern Recognition Principles**. Massachusetts: Addison-Wesley, Publishing Company, Reading. 1974. 377p.
- XU, L.; KRZYZAK, A; E SUEN, C. Y. Methods of combining multiple classifiers and their applications to handwriting recognition. **IEEE Transactions on System, Man, and Cybernetics**, vol. 22, pp. 418–435, 1992.