



COMPARAÇÃO DOS MÉTODOS SUPPORT VECTOR MACHINE E MÁXIMA VEROSSIMILHANÇA GAUSSIANA PARA CLASSIFICAÇÃO DE IMAGENS ORBITAIS GEOEYE DAS ÁREAS DE DUNAS COSTEIRAS DA PRAIA DO CASSINO, RIO GRANDE, RS

Lisandra Roldão Miranda¹, Delnir Monteiro de Lemos² & Jean M. de Almeida Espinoza²

¹ Universidade Federal de Pelotas, Rua Gomes Carneiro, 01 – Pelotas - RS, Brasil, CEP: 96.010-610, lisproldao@gmail.com.

² Instituto Federal do Rio Grande do Sul, Campus Rio Grande, Rua Eng. Alfredo Huck, 475 – Centro, Rio Grande - RS, Brasil, CEP: 96.201-460, delnir.lemos@riogrande.ifrs.edu.br jean.espinoza@riogrande.ifrs.edu.br.

RESUMO

A classificação de imagens de orbitais possui uma variedade de métodos para análise espectral, porém a escolha deles dependerá da área a ser estudada. Este trabalho apresenta, com foco para a aplicação das técnicas de Processamento Digital de Imagens, a classificação supervisionada da extensão das dunas costeiras do Balneário Cassino, no município do Rio Grande/RS, utilizando os classificadores *Support Vector Machines* (SVM) e Máxima Verossimilhança Gaussiana (MVG). Esses métodos proporcionaram implementar a análise de acurácia baseada na matriz erro e a comparação entre os classificadores. A partir da imagem de alta resolução espacial Geoeeye, com o auxílio do software MatLab®, as amostras de treinamento foram coletadas para treinar os algoritmos de classificação implementados na cena segmentada. Os resultados deste trabalho foram avaliados visualmente, assim comparando os métodos pela sua eficiência na classificação de imagem da área de estudo e trazendo subsídios para futuros interessados em classificadores para a área de dunas costeiras.

Palavras-chave: Classificação, PDI, dunas, supervisionada.

COMPARISON OF SUPPORT VECTOR MACHINE AND MAXIMUM GAUSSIAN VERISIMILTY METHODS FOR CLASSIFICATION OF GEOEYE ORBITAL IMAGES OF CASSINO BEACH AND COASTAL DUNES AT RIO GRANDE, RS

ABSTRACT

The classification of satellite images has a variety of methods for spectral analysis, but the choice of them depends on the area being studied. This work presents, with the techniques of Digital Image Processing, supervised classification of the extension of the coastal dunes of the Balneário Cassino, in the city of Rio Grande, using the classifiers Support Vector Machines (SVM) and Maximum Gaussian Likelihood. These classifications provided to implement the analysis of accuracy based on the matrix error and the comparison between the classifiers. From the high spatial resolution Geoeeye image, with the aid of MatLab software, the training samples were collected to train the classification algorithms implemented in the segmented scene. The results of this work were evaluated visually, thus comparing the methods for their efficiency in the image classification of the study



area and bringing subsidies to interested parties in classifiers for the coastal dune area.

Keywords: Classification, DIP, dunes, supervised.

INTRODUÇÃO

A classificação de imagens digitais leva em consideração as classes espectrais para extrair seus dados, mas dependendo da área de estudo essas divisões possuem valores de médias próximos entre si, necessitando de dimensões espectrais altas para separação apropriada dos dados (ANDREOLA, 2009). Baseado nesta afirmação dentro das técnicas de Processamento Digital de Imagens (PDI) existem diversos métodos para classificação de imagens de satélites, como por exemplo, a distância mínima, K-média, ISODATA e árvore de decisão (NASCIMENTO et al, 2009).

Inseridos nesses métodos de classificação temos também o Support Vector Machine (SVM) e Máxima Verossimilhança Gaussiana (MVG), caracterizados como métodos supervisionados e paramétricos no processamento de imagem deste trabalho. Os métodos supervisionados baseados na definição das classes e na coleta dos pixels de treinamento representativos de cada classe (MATHER & TSO, 2009), realizam cálculos a partir dessas amostras para ser referência nas demais classificações.

Os métodos paramétricos baseados nas amostras de treinamento, pixels de valores conhecidos, estimam a densidade de probabilidade do comportamento dos dados das classes (ANDREOLA, 2009), possuindo previamente seu valor. Também salientar que um método pode também ser considerado não paramétrico quando não é possível conhecermos a densidade de probabilidade do comportamento dos dados (SEMOLINI, 2002). No caso do método Support Vector Machine (SVM), este pode ser aplicado na classificação de imagens, como não supervisionado. O

SVM une as informações pela semelhança e separa pela diferença dos valores de cada pixel na imagem para discriminar as classes, não necessitando de pixels pré-definidos (LORENA & CARVALHO, 2007).

A fim de comparar os semelhantes métodos, citados anteriormente, a área de estudo definida para este estudo foi a extensão de dunas costeiras da praia do Cassino, litoral do Rio Grande do Sul, pela sua função ambiental como Área de Preservação Permanente (APP), sendo assegurada pela Resolução do Conselho Nacional do Meio Ambiente (CONAMA) n° 302/2002.

Sendo assim, os objetivos deste trabalho foram realizar a comparação dos métodos de classificação Support Vector Machine (SVM) e Máxima Verossimilhança Gaussiana (MVG) em uma imagem do satélite Geoeye da extensão das dunas costeiras do Balneário Cassino, classificação da área de estudo com os métodos SVM e MVG, análise dos dados gerados, e a implementação da análise de acurácia baseada da matriz de erro dos dados resultantes das classificações.

CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo definida para realização desse trabalho é a extensão das dunas costeiras da praia do Cassino, localizada no balneário Cassino dentro do município de Rio Grande no estado do Rio Grande do Sul (Figura 1). O recorte espacial utilizado corresponde ao início da localidade do ABC, no arroio do Gelo, até o final da praia do Cassino.

O ecossistema de dunas costeiras é definido como uma faixa paralela a linha de costa estabelecida no pós-praia, constituído por sedimentos granulares que são levados pelos ventos e depositados em locais quando encontram barreiras, geralmente essas são vegetações (CALLIARI et al., 2005). Sendo um território legalmente protegido pela sua vulnerabilidade ambiental e pelas suas funções de



anteparo da costa, proteção dos lençóis freáticos e preservação da fauna e flora.




Figura 1: Área de estudo.

O ecossistema de dunas costeiras é definido como uma faixa paralela a linha de costa estabelecida no pós-praia, constituído por sedimentos granulares que são levados pelos ventos e depositados em locais quando encontram barreiras, geralmente essas são vegetações (CALLIARI et al., 2005). Sendo um território legalmente protegido pela sua vulnerabilidade ambiental e pelas suas funções de anteparo da costa, proteção dos lençóis freáticos e preservação da fauna e flora.

As dunas costeiras são formadas pela interação dos ventos, areia e vegetação (NEMA, 2006), com a função ambiental de resguardo da costa, proteção dos lençóis freáticos e a preservação da fauna e flora, sendo Áreas de Preservação Permanente (APP).

A área de APP caracteriza-se pela sua fauna e flora contendo, respectivamente, o tuco-tuco, maçarico de colar, sapo das dunas, entre outros animais silvestres e na sua flora a catiporágua, margarida das dunas, capim das dunas, entre outras vegetações. Segundo o Núcleo de Educação e Monitoramento Ambiental - NEMA (2006), essa APP, como diversas outras áreas ambientais, enfrenta o conflito entre a urbanização, o uso da praia e sua preservação, esse que vem desde 1996, sendo confrontado com avanços em comparação ao início. Mas como se trata de um sistema contínuo, a sua preservação torna-se também contínua e sustentável, um bom exemplo desse resguardo é a construção da passarela na praia do Cassino que permite o acesso a ela sem a necessidade da retirada da areia (NEMA, 2006).

MATERIAIS E MÉTODOS

A Figura 2 apresenta os procedimentos metodológicos desta pesquisa.

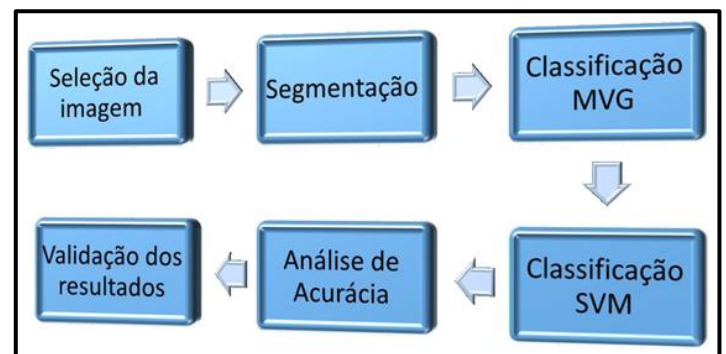


Figura 2: Fluxograma metodológico.

O trabalho foi desenvolvido com a utilização de uma imagem de alta resolução espacial Geoeye, adquirida em 5 de dezembro de 2015, via projeto do curso técnico de Geoprocessamento do Instituto Federal do Rio Grande do Sul em colaboração com a Prefeitura Municipal do Rio Grande, e o software MatLab. A imagem foi georeferenciada no sistema de coordenadas SIRGAS 2000.



A imagem Geoeye, que foi selecionada, possui o total de 4 bandas, sendo elas do vermelho (R), verde (G), azul (B) e infravermelho próximo (NIR). A resolução espacial é de 50 cm no pancromático e de 2 m multiespectral, união do RGB, que consiste na tomada de diferentes comprimentos de onda eletromagnética do alvo.

Seguindo a metodologia, a segmentação consiste no agrupamento de pixels semelhantes (MENESES & ALMEIDA, 2012), se optou pelo o software MATLAB para efetuar a segmentação por crescimento de regiões. Essa que inicialmente distribui pontos aleatoriamente espalhados pela cena (sementes), as quais proporcionam o crescimento das regiões a partir do *pixel* em que está a semente pela junção dos *pixels* vizinhos que apresentam propriedades semelhantes (ZANOTTA, 2014).

Assim, de maneira exploratória, foi definido como 5x5 pixels o tamanho mínimo para as regiões e o limiar de similaridade utilizado foi de 10%. É necessário ressaltar que pelo tamanho da imagem ser de 6.209 linhas por 9.599 colunas, foi preciso determinar ao segmentador dividir em dez retângulos a cena inteira, isso otimizou o processo e acrescentou peculiaridades ao resultado final, pois o algoritmo segmentou cada retângulo independente dos demais.

Com finalidade de realizar a metodologia proposta foram definidas as classes corpos d'água, vegetação e sedimentos. Visto que, o ecossistema dunar é composto pela interação entre vegetação e sedimentos (NEMA, 2006), as classes vegetação e sedimentos das dunas se tornam essenciais na classificação. Assim como, a classe corpos d'água é relevante pelo ecossistema de dunas costeiras estar presente ao longo da praia do Cassino.

Ainda para melhorar o resultado das classificações se optou por subdividir as classes já citadas, em grupos com menores segmentos (Tabela 1),

para efetivar o processamento e a coleta dos pixels de treinamento necessários nas classificações supervisionadas.

Tabela 1: Classes utilizadas na classificação supervisionada.

Classe geral	Classes subdivididas	Referente
Corpos d'água	Corpos d'água 1	Arroio
	Corpos d'água 2	Mar
	Corpos d'água 3	Corpos d'água entre a vegetação
Sedimentos	Sedimentos 1	Sedimentos a beira mar
	Sedimentos 2	Sedimentos entre a beira mar e as dunas
	Sedimentos 3	Sedimentos do mar
Vegetação	Vegetação 1	Vegetação clara
	Vegetação 2	Vegetação escura

Na sequência foram implementados os classificadores supervisionados *Support Vector Machine* e Máxima Verossimilhança Gaussiana, com as bandas 3 e 4 da imagem Geoeye. No MVG são inseridos pixels de treinamento das classes, ou seja, pixels de valores conhecidos, para estimar a forma da distribuição deles no espaço das bandas e localizar o centro de cada classe. Baseado nisso são realizados cálculos estatísticos para determinar o pertencimento de cada *pixel* à classe que tem a mais alta probabilidade (MENESES & ALMEIDA, 2012).

O classificador SVM gera um hiperplano, em que a distância entre um conjunto de classes dos dados possibilita a classificação e diferenciação deles. Esses dados podem ser identificados a partir de sua separação, como lineares e não lineares (ANDREOLA, 2009) definidos a partir das amostras de treinamento.

Os dados lineares requerem no código funções lineares e margens rígidas, no qual as restrições asseguram que não tenham dados entre as margens do hiperplano. Quanto aos dados não lineares, o algoritmo necessita de funções não lineares e margens suaves no hiperplano, em que variáveis são inseridas para atenuar



as restrições tendo a possibilidade de permanência de dados no hiperplano. No caso da pesquisa, o classificador SVM dados não lineares, sendo assim possuía um hiperplano de margens suaves.

As amostras de treinamento foram coletadas sobre a imagem Geoeye para treinar os algoritmos do Support Vector Machines (SVM) e Máxima Verossimilhança Gaussiana (MVG) para serem implementados na cena Geoeye segmentada por crescimento de regiões. Em que, o SVM utilizou o kernel Radial Basis Function (RBF), enquanto o MVG usou o limiar segundo análise de cada um dos pixels.

A fim de verificar os resultados obtidos nas classificações dos métodos SVM e MVG, foi realizada uma saída de campo no dia 13 de novembro de 2017 com o objetivo de melhor identificar as classes na área de dunas costeiras da praia do Cassino. A saída de campo foi realizada ao longo da extensão da cena Geoeye, possibilitando averiguar a localização das classes nas dunas (Figura 3).

Também foi realizada a análise da matriz erro representou a uniformidade entre os resultados das classificações possibilitando o cálculo dos erros de omissão e comissão de cada método de classificação. Os erros de omissão acontecem quando o pixel é excluído da sua classe pertencente, sendo referenciado em outra. Enquanto, nos erros de comissão, o pixel é incluído em uma classe, porém corresponde a outra classe. Logo, erros de comissão geram erros de omissão (ALBUQUERQUE, 2012).

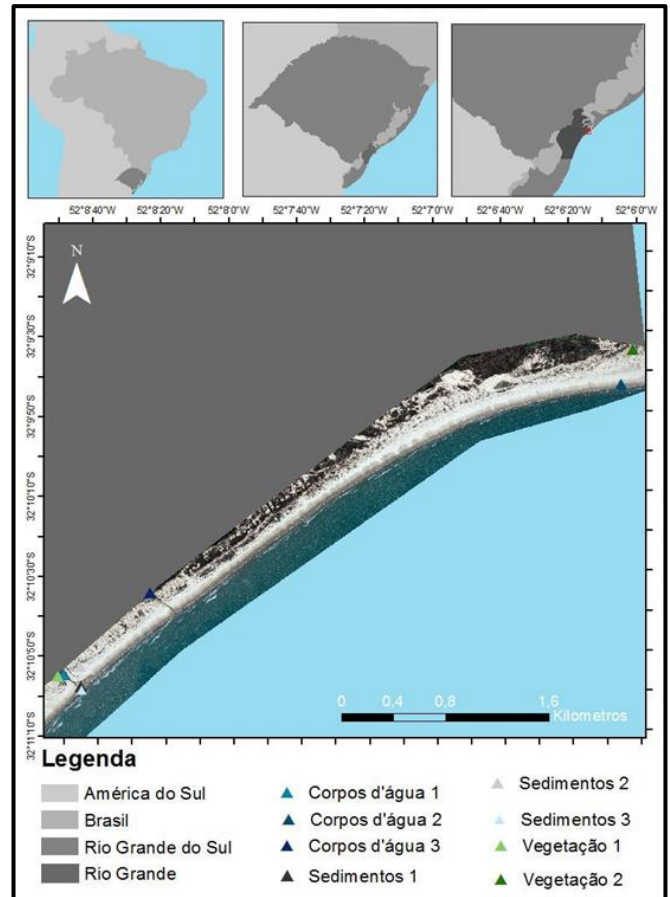


Figura 3: Mapa de pontos de localização das classes .

RESULTADOS

Os resultados deste trabalho foram à segmentação por crescimento de regiões na imagem Geoeye da área de estudo, (Figura 4), a qual teve por objetivo dividir a imagem em regiões ou objetos para facilitar a sua análise, a classificação da segmentação pelo método de classificação *Support Vector Machine* (SVM), e a classificação da mesma cena pelo método Máxima Verossimilhança Gaussiana (MVG).

A Figura 5 apresenta a classificação da segmentação imagem *Geoeye* pelo método de classificação *Support Vector Machine* (SVM) com as classes definidas na Figura 3. Seguida, pela Figura 6 que traz a classificação da mesma cena pelo método Máxima Verossimilhança Gaussiana (MVG). Salientando que para realização das classificações as bandas definidas foram a 3 e 4.




Figura 4: Imagem da segmentação área de estudo da imagem Geoeye (a) extensão total (b) recorte da segmentação.

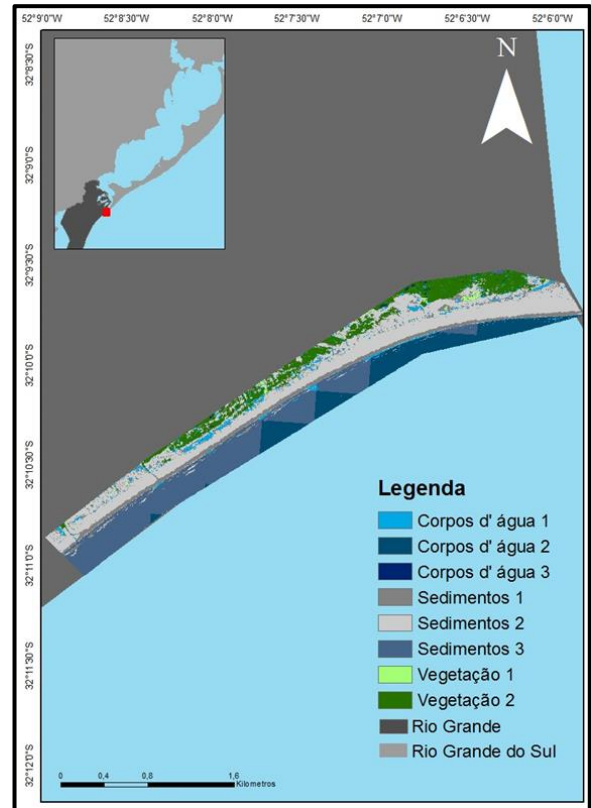


Figura 6: Classificação da imagem Geoeye com o método Máxima Verossimilhança Gaussiana (MVG).

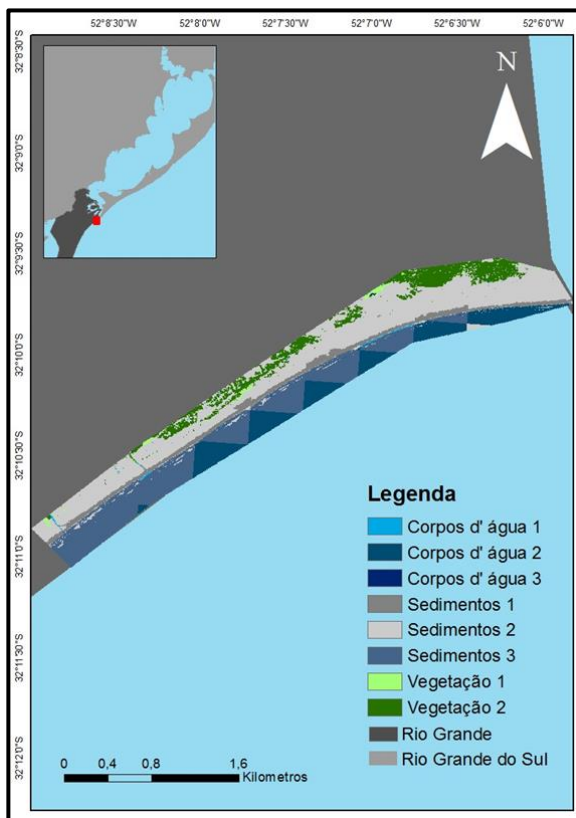


Figura 5: Classificação da imagem Geoeye com o método *Support Vector Machine* (SVM).

DISCUSSÃO

Na análise visual dos resultados das classificações foi possível observar a confusão do classificador SVM entre as classes corpos d'água 2 e sedimentos 1 com sedimentos 2, essas confusões que podem ser esclarecidas pela segmentação ter sido dividida em retângulos, desse modo segmentos de mesma classe ficaram com padrões de cores diferentes. Os quais, são quase imperceptíveis na imagem segmentada e não são visíveis na imagem original usada para coleta de amostras, como mostra a Figura 7.

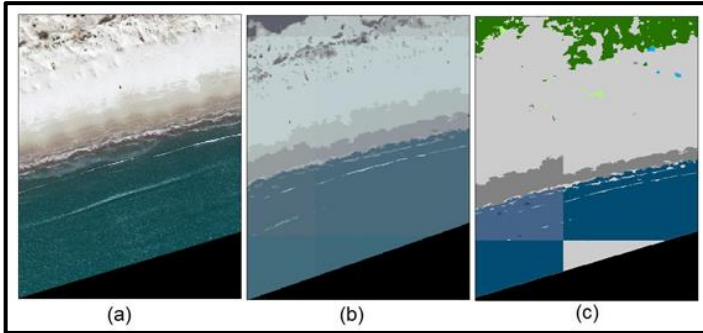


Figura 7: Confusão entre as classes corpos d' água 2 com sedimentos 2 (a) imagem Geospatial (b) segmentação da imagem (c) classificação SVM da segmentação.

Enquanto, o classificador MVG teve maior confusão entre corpos d' água 1, sedimentos 1 e vegetação 1 com sedimento 2, essas confusões que também podem ser atribuídas à semelhança de cor entre os pixels de treinamentos coletados nas classes (Figura 8).




Figura 8: Confusão entre as classes corpos d' água 1, sedimentos 1 e vegetação 1 com sedimentos 2 (a) imagem Geospatial (b) segmentação da imagem (c) classificação MVG da segmentação.

Em comparação aos resultados dos métodos SVM e MG, encontramos erros similares de classificação, como a confusão da classificação entre corpos d' água 1 e sedimentos 3, que acontece pela diferença de cor da classe sedimentos 3 na área em questão dentro da segmentação provocando o erro nos dois métodos (Figura 9).




Figura 9: Confusão entre as classes corpos d' água 1 com sedimentos 3 (a) imagem Geospatial (b) segmentação da imagem (c) classificação SVM (d) classificação MVG da segmentação.

Outro equívoco dos classificadores *Support Vector Machine* (SVM) e *Máxima Verossimilhança Gaussiana* (MVG) na classificação foi um local que na imagem original e na segmentada representava a vegetação 1, mas cada um dos métodos optou em classificar relacionado a outra classe, em que o SVM classificou como sedimentos 2 e o MVG como sedimentos 3, isso ocorreu pela imagem de coleta possuir resquícios de sedimentos, assim cada classificador optou por designar, essa vegetação para uma das classes de sedimentos que acreditou ser mais correta (Figura 10).






Figura 10: Confusão de classificação (a) imagem Geoeye (b) segmentação da imagem (c) classificação SVM (d) classificação MVG da segmentação.

Tanto o classificador SVM quanto o MVG obtiveram respostas divergentes na qual, a partir da validação a campo podemos perceber que o *Support Vector Machine* (SVM), pela Figura 11, teve um resultado próximo do real. O SVM classificou a área como corpos d' água 1, sedimentos 2 e, vegetação 1 e 2, Enquanto o MVG afirmou a presença da classe vegetação 2 dentro do arroio do Gelo e a presença das classes corpos d' água 1 e sedimentos 2 ao lado do arroio.




Figura 11: Confusão de classificação (a) imagem Geoeye (b) segmentação da imagem (c) classificação SVM (d) classificação MVG da segmentação.

Além disso, é importante ressaltar que pela área de estudo ser uma praia, temos a presença das ondas, as quais influenciaram negativamente o resultado das classificações, pois durante a aplicação da metodologia não foi possível diferenciá-las em uma única classe, pela sua forma dispersa ao longo de toda extensão do litoral. Desse modo, optamos por permitir que os classificadores SVM e MVG decidissem em qual classe as ondas deveriam estar presentes, assim o SVM classificou como sedimentos 2 e o MGV como sedimentos 1 e 2.

Analisando cada uma das matrizes erro (tabelas 2 e 3) percebemos que o método de classificação *Support Vector Machine* obteve menos erros de omissão e comissão em seu resultado, sendo assim sua matriz é mais acurada. Na qual, somente nas classes corpos d' água 2 e sedimentos 3 teve número significativo de pixels classificados incorretamente.

Classes	Classes									TOTAL
	Corpos d'água			Sedimentos			Vegetação			
	1	2	3	1	2	3	1	2		
Corpos d'água	1	4305	0	0	14	2	0	0	0	4321
	2	0	54927	0	0	0	2991	0	0	57918
	3	0	0	1024	0	0	0	0	0	1024
Sedimentos	1	345	0	0	155122	122	1	0	0	155590
	2	3	0	0	442	469743	0	7	78	470273
	3	0	6	0	1	0	151438	0	0	151445
Vegetação	1	0	0	0	0	0	0	16731	0	16731
	2	2	0	0	0	17	0	1	73499	73519
TOTAL		4655	54933	1024	155579	469884	154430	16739	73577	930821

Tabela 2: Matriz erro da classificação com o método SVM.

Classes	Classes									TOTAL
	Corpos d'água			Sedimentos			Vegetação			
	1	2	3	1	2	3	1	2		
Corpos d'água	1	2491	898	0	12122	5858	7525	4323	9177	42384
	2	0	42593	0	0	0	48485	1401	80	92559
	3	64	1	981	57	34	1	298	4889	6325
Sedimentos	1	481	395	0	129406	30547	2566	844	388	164627
	2	5	27	0	13929	431728	140	142	17	445988
	3	210	10713	0	2	6	95475	1339	650	108395
Vegetação	1	229	257	0	13	351	22	1070	3481	5423
	2	1175	49	43	50	1360	216	7322	54895	65110
TOTAL		4655	54933	1024	155579	469884	154430	16739	73577	930821

Tabela 3: Matriz erro da classificação com o método MVG.

Enquanto o método MVG apresentou grande número de erros em sua matriz, em especial nas classes de vegetação 1 e 2. A única classe que obteve um resultado melhor foi na classe de sedimentos 3 havendo confusão somente com vegetação 2. Esse resultado de acurácia pode ser explicado pela variância das classes serem similares, o que confundiu o método ao definir sua função decisão pela ponderação em relação às médias.

CONCLUSÕES

Ao longo da presente pesquisa foi realizada a comparação entre os métodos de classificação *Support Vector Machine* (SVM) e *Máxima Verossimilhança Gaussiana* (MVG) na área de dunas costeiras do Balneário Cassino. Ambos os métodos atingiram os



resultados esperados que foi classificar as dunas. Porém, baseado nos resultados obtidos de cada método é visível que para escolher qual deles é mais adequado para a área de dunas costeiras, depende diretamente do objetivo do estudo.

Visto que o classificador Support Vector Machine (SVM) obteve o melhor resultado pela matriz erro alcançando menos erros na classificação, esse método se torna uma melhor escolha quando o objetivo do estudo é a realização da detecção de mudanças, pois sua classificação possui áreas mais definidas para todas as classes, assim possibilitando analisar as áreas de mudanças positivas e negativas nas dunas costeiras.

O classificador Máxima Verossimilhança Gaussiana (MVG) não alcançou bons resultados na sua matriz erro possuindo mais erros de confusão entre as classes. Mas ainda é uma boa escolha quando o objetivo do trabalho é a comparação da imagem classificada com a imagem original das dunas costeiras, pois esse método é mais autêntico nas formas das classes, sendo sua classificação mais semelhante com a imagem original.

Também, é importante ressaltar que a imagem de alta resolução escolhida, acabou trazendo dificuldades para aplicação da metodologia, pois apresenta grande quantidade de pixels, assim necessitando de um computador adequado para o seu processamento o que, entretanto, não evitou a utilização de um tempo considerável para a sua execução.

AGRADECIMENTOS

Agradecemos a oportunidade de participar do VIII Encontro da Rede Braspor realizado no município de Rio Grande, o qual é berço do nosso campus do Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul – IFRS.

REFERÊNCIAS

ALBUQUERQUE, W. R. Monitoramento Da Cobertura Do Solo No Entorno De Hidrelétricas Utilizando O Classificador Svm (Support Vector Machines) No Entorno De Hidrelétricas Utilizando O Classificador Svm (Support Vector Machines). São Paulo: Escola Politécnica da Universidade de São Paulo, 2012. Dissertação - Programa de Pós-Graduação em Engenharia de Transportes, Escola Politécnica da USP.

ANDREOLA, R. 2009. “Support Vector Machines na classificação de imagens hiperespectrais”. Porto Alegre, UFRGS. Dissertação – Programa de Pós-Graduação em Sensoriamento Remoto do Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, UFRGS.

NASCIMENTO, R. F. F; ALCÂNTAR, E. H; KAMPEL, M; STECH, J. L & NOVO, E. M. L. M; FONSECA, L. M. G. 2009. “O algoritmo SVM: avaliação da separação ótima de classes em imagens CCD-CBERS-2”. Natal, XIV Simpósio Brasileiro de Sensoriamento Remoto, p. 2079-2086.

MATHER, P. & TSO, BT. 2009. “Classification Methods for Remotely Sensed Data”. 2. ed. London, CRC Press.

LORENA, A. & CARVALHO, A. 2007. “Uma introdução às Support Vector Machines”. Revista de informática teórica e aplicada. São Paulo, v. 14, n. 2, p. 43-67.

SEMOLINI, R. 2002. “Support Vector Machines, Inferência Transdutiva e o Problema de Classificação”. Dissertação (Mestrado em Engenharia de Computação) - UNICAMP. Campinas, SP.

CONAMA. Resolução nº 302, de 20 de março de 2002.

MENESES, P. R.; ALMEIDA, T. Introdução ao Processamento de Imagens de Sensoriamento Remoto. Brasília: CNPq/UnB, 2012.

NEMA - Núcleo de Educação e Monitoramento Ambiental. 2006. “Plano de Manejo das Dunas Costeiras do Município de Rio Grande”. Rio Grande.



ZANOTTA, D. Uma metodologia adaptativa baseada em objetos para detecção semi-automática de desmatamento na Amazônia por imagens de sensoriamento remoto. São José dos Campos: INPE, 2014. Tese – Pós-graduação em Sensoriamento Remoto, INPE.