
UTILIZAÇÃO DO ALGORITMO SVM (SUPPORT VECTOR MACHINE) E ÁRVORES DE DECISÃO PARA CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO DO SENSOR ADS-40.

ELIZABETE BUGALSKI DE ANDRADE PEIXOTO ¹
PROF. DR. HIDEO ARAKI ¹
PROF.DR JORGE CENTENO ¹

Universidade Federal Do Paraná – UFPR
Curso De Pós-Graduação Em Ciências Geodésicas - PPGCG
Caixa Postal 515 – CEP 12201-970 – Curitiba/PR – Brasil
hideo@ufpr.br, elizabeth@esteio.com.br, centeno@ufpr.br

RESUMO - O objetivo deste trabalho é avaliar os métodos de classificação de feições SVM Support Vector Machine e Árvore de Decisão em imagem oriundas do sensor Leica ADS-40. Foram apresentados os resultados do experimento que demonstram as exatidões obtidas com o uso desses algoritmos.

ABSTRACT - The aim of this research is evaluate the classification methods SVM Support Vector Machine and Decision Tree features with Leica ADS-40 sensor. Experiment's results were presented showing the accuracies obtained from using these algorithms.

1 INTRODUÇÃO

Na área de Ciências Cartográficas, o problema de extração de feições tem sido fundamental há mais de duas décadas, seja na automação dos algoritmos existentes, como na elaboração de novos algoritmos mais eficazes. O Sensoriamento Remoto tem se mostrado uma forma eficaz de fornecer dados para que essa atividade seja mais fácil, através das imagens infravermelhas que alguns sensores de alta qualidade fornecem, bem como, dados LiDAR que possibilitam vários tipos de extrações.

A extração automatizada de informações a partir de imagens tenta reproduzir como o cérebro consegue interpretar as feições. Uma maneira de tornar a interpretação de imagens mais simples consiste em separar grupos de pixels com características espectrais similares. Antes da interpretação de imagens adquiridas e não devidamente processadas, tem-se apenas "dados de sensores remotos". Depois da interpretação dessa imagem, esses dados são transformados em "informação útil" (LILLESAND;KEIDE, 1994;FLOPRENZANO, 2002).

Para se classificar uma imagem em categorias de interesse, o algoritmo de classificação necessita de treinamento. Esse treinamento define se a classificação é supervisionada ou não supervisionada. A classificação supervisionada é quando já existe um conhecimento prévio da área e o usuário identifica pontos como amostras. . O não supervisionado é quando a definição dos grupos, mais freqüentes, na imagem é feita automaticamente pelo computador, analisando a distribuição dos valores do contador digital. Os classificadores supervisionados podem ser paramétricos ou não paramétricos. Os paramétricos pressupõem um conhecimento sobre a estatística dos dados e os não paramétricos não necessita de uma distribuição estatística *a priori*.

Quando não se tem certeza da distribuição Gaussiana dos dados, como por exemplo quando se lida com alturas de uma varredura Lidar, algoritmos não paramétricos são mais recomendados para a classificação, como por exemplo os classificadores SVM (*Support VectorMachine*) e Árvores de Decisão, que são supervisionados e não paramétricos. Eles são muito utilizados na classificação de imagens oriundas de sensores remotos, fazendo com que alguns estudos apresentem essas técnicas como classificadores supervisionados mais inteligentes que os convencionais.

Neste trabalho é apresentado um estudo comparativo destes dois algoritmos de classificação para a classificação de uma imagem RGB, uma Infravermelha e uma imagem oriunda de um perfilamento a laser, bem como, apresentar uma análise comparativa entre os resultados, contribuindo assim em futuras aplicações no Processamento Digital de Imagens.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 SVM (Support Vector Machines)

O SVM é uma técnica para classificação binária, ou seja, realiza uma separação automática entre duas classes distintas (VAPNIK, 1995). O Support Vector Machine (SVM) representa uma generalização do algoritmo, desenvolvido na Rússia nos anos 60, Generalized Portrait, sendo baseado em vetores-suporte como estratégia de aprendizado, solidamente fundamentado na teoria de aprendizado estatístico, ou teoria VC (Vapnik-Chervonenkis) (LIMA, 2004). Apenas a partir dos anos 90 suas aplicações começaram a ganhar notoriedade.

Conforme Burges (1998), Support Vector Machines é uma ferramenta que fornece uma nova abordagem para o problema de reconhecimento de padrões. SVM é um classificador supervisionado que tem por objetivo encontrar um hiperplano que separa um conjunto de dados em classes discretas, utilizando-se de processo iterativo e de exemplos de treinamento para ajustar este hiperplano. Para isto, SVM encontra um hiperplano que otimiza a separação das classes, também conhecido como hiperplano ótimo ou ideal, que maximiza a distância entre as classes, sendo usado como fronteira de decisão. (Zhu e Blumberg, 2002 apud Mountrakis et al., 2011; Kavzoglu e Colkesen, 2009; Petropoulos et al., 2012; Costa et al., 2010; Andreola e Haertel, 2009).




Figura 1 - Exemplo de classificação SVM.

A melhor decisão é aquela que apresenta a maior margem entre duas classes distintas processo de classificação dos dados. O Support Vectors é exatamente a margem, foi que deu origem ao nome. São nada mais que pontos de ambas as classes que estão mais próximos do separador de classes. A determinação desses vetores é importante para estabelecer a função separadora de classes, pois o algoritmo faz uso desses dados para gerar a classificação. O número de vetores é menor que a quantidade total de amostras de cada classe.




Figura 2 - Support Vectors

O hiperplano de separação, ou função de separação, é um plano de dimensão única que separa um espaço amostral em duas classes conforme apresentado na figura 3.




Figura 3 - Hiperplano de separação

O hiperplano que possui a maior margem será considerado um hiperplano de separação ótima, conhecido como OSH (Optimal Separating Hyperplane) e sua equação mostra a margem a ser maximizada para essa condição.

$$\tilde{L}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij} \alpha_i \alpha_j y_i y_j x_i^T x_j \tag{1}$$

onde: x_i é um conjunto de treinamento,
 y_i são os rótulos
 α são os multiplicadores de Lagrange

As funções Kernel entram para solucionar os casos onde os problemas não são lineares e apresentam grande importância. Elas representam formas mais complexas que hiperplanos lineares, e as funções Kernel mais utilizadas são linear, RBF Radial Basis Function, polinomial e sigmoide. Neste trabalho será utilizada a função RBF e mais referenciada nos trabalhos com imagens.

Nos últimos anos, o SVM vem sendo utilizado em vários estudos tendo um aumento significativo, até sendo comparado como um melhor classificador que as RNA's.

2.2 Árvores de decisão

As árvores de decisão é uma abordagem não paramétrica de reconhecimento de padrões. É uma estrutura normalmente usada para implantação de sistemas especialistas e para classificações. Funciona similarmente com a regra if-then.

A entrada é uma situação com determinados atributos contínuos ou discretos, que solicita uma decisão. Posteriormente é realizada uma sequência de testes até que a árvore de decisão chegue ao final. Cada nó interno da árvore corresponde a um teste do valor de uma das propriedades e os ramos deste nó são identificados com os possíveis valores do teste. Cada nó folha da árvore especifica o valor de retorno se a folha for atingida. O mais importante de uma árvore de decisão é a escolha dessas regras que definirão o caminho até a folha. Na figura 4 tem um exemplo de estrutura de uma árvore de decisão. Os nós quadrados representam decisões e os redondos representam incerteza.




Figura 4 - Estrutura de Árvore de Decisão

Os atributos de uma árvore de decisão são definidos de acordo com critérios estatísticos que sejam os mais relevantes para a classificação. A entropia ou ganho de informação é uma das medidas de seleção de atributos baseada

em impureza dos dados. O cálculo da entropia pode ser definido através da equação (2) e da entropia para cada atributo de decisão (2.1):

$$\text{entropia}(S) = - \sum_{i=1}^n = 1 * \frac{c_j}{S} * \log_2 \frac{c_j}{S} \quad (2)$$

$$\text{entropia}(S,A) = \sum_{i=1}^n = \frac{S_i}{S} * \text{entropia}(S) \quad (3)$$

Onde:

- Cj: quantidade de amostras da classe,
- S: quantidade total das amostras.
- Si: quantidade de amostras para a partição
- m: quantidade de partições
- Entropia(Si): entropia total para a partição

O ganho máximo seleciona o atributo que possui o maior ganho de informação esperado, isto é, seleciona o atributo que resultará no menor tamanho esperado das subárvores, assumindo que a raiz é o nó atual. Ele possui tendência em favor de testes com muitos valores. A escolha do atributo para particionar o conjunto de exemplos é dada pelo cálculo do ganho de informação de cada atributo. Esse cálculo consiste na subtração da entropia de todo o conjunto pela entropia de cada atributo, como definido pela equação (3)

$$\text{ganho}(S,A) = \text{entropia}(S) - \text{entropia}(S,A) \quad (4)$$

O atributo entre todos os utilizados na classificação das amostras que possui o maior valor de ganho de informação é o atributo com ganho máximo, e assim o mais relevante para particionar os exemplos classificando-os. A partir da primeira seleção de um atributo para particionar os exemplos é feita as escolhas para a partição e classificação nas sub-árvores até a classificação total de todos os exemplos do conjunto. E o critério de avaliação para testes com poucos valores é a Razão de Ganho.

$$\text{ratio}(S,A) = \frac{\text{ganho}(S,A)}{\text{entropia}(S,A)}(S) \quad (5)$$

Os algoritmos de árvores de decisão são conhecidos pelo seu poder de expressividade, encadeando um conjunto de testes, os quais atuam diretamente no ganho de informação a respeito dos dados. Há a possibilidade de transformarmos árvores de decisão em regras de classificação

Existem vários algoritmos para árvores de decisão, como o ID3, C4.5 e o CART. Alguns consistem em crescimento e poda como é o caso do C4.5 e CART e outros apenas na fase de crescimento.

O J48 se baseia no algoritmo de árvores de decisão C4.5, que forma a árvore mais adequada sobre o conjunto de dados, podando as regras que melhoram a sua acurácia. Ele realiza o trabalho de classificação de uma forma recursiva onde os dados utilizados para treinamento são divididos em subconjuntos e o algoritmo interrompe quando encontra o nível desejado de semelhança. A identificação da raiz e dos seus descendentes é realizada pelos cálculos de ganho e entropia, já conceituados anteriormente.

3. MATERIAIS E MÉTODOS

A área de estudo está localizada na cidade de Porto Alegre no Estado do Rio Grande do Sul e refere-se ao Parque Farroupilha. Possui 37,5 hectares.

O Parque Farroupilha é considerado o parque mais tradicional da cidade de Porto Alegre. Também conhecido como Parque da Redenção é um lugar que durante a Revolução Farroupilha ficou do lado de fora das fortificações da cidade por ser uma área de várzea. Com o passar do tempo, a área foi tombada como patrimônio histórico.

O levantamento aerofotogramétrico foi realizado com equipamento Leica ADS-40 e o perfilamento a laser com o equipamento Leica ALS 50-II, ambos em dezembro de 2010. A ADS 40 é um sensor digital de varredura em linha (pushbroom), de alta resolução tanto radiométrica como geométrica, com três visadas (anterior, nadir e posterior) e opera nas bandas do visível (RGB) e no infravermelho próximo (IR). Ambos os sistemas possuem o sensor, um GPS\IMU montados numa plataforma rígida, conforme apresentado na figura 5.



Figura 5 ADS40 e ALS50.

Neste trabalho foram utilizadas imagens ortoretificadas com resolução espacial de 0,20 metros e os dados LIDAR possuem a densidade de três pontos por metro quadrado.



Figura 6 - Área de estudo

3.1 SVM

Inicialmente foi utilizado o software Envi 4.7 que realiza tanto a classificação SVM pixel a pixel, bem como, árvore de decisão.

Para a classificação supervisionada SVM foi utilizada a imagem RGB e adotaram-se as combinações do parâmetro gamma da função kernel RBF Radial Basis Function nos valores de 0,3; 100; 1; 1,0 e 0 e 0,7; 90; 1; 1,0 e 0. Foi utilizada a função RBF por ser referenciada em vários trabalhos de classificação como sendo a mais adequada para imagens de alta qualidade.

Para a construção da árvore de decisão foi utilizada a imagem infravermelha e o modelo digital de superfície normalizado apresentadas nas figuras 7 e 8.

Na tabela 1 estão apresentadas as classes escolhidas para o treinamento da imagem.

Tabela 1 - Relação das classes

Classe	Cor	Pixels	Polígonos
Vegetação	Vermelha	28.876	4
Água	Água	6.986	2
Asfalto	Asfalto	15.955	12
Edificação	Edificações	19.318	14




Figura 7 - Classes

Como a imagem possui alta resolução, o processamento é lento. Para solucionar isso, o próprio software sugere baixar a resolução antes do processamento.

3.2 Árvore de Decisão

Para a classificação de forma recursiva foi utilizado o algoritmo J48, a partir de duas imagens, uma infravermelha, apresentada na figura 8, que possibilita a separação da vegetação das outras classes e do modelo digital de superfície normalizado, ou seja, o modelo de superfície subtraído o modelo de terreno, apresentado na figura 9, que possibilita a partir das alturas separar elementos com valores espectrais semelhantes.

Como a construção de árvores de decisão é realizada por processo de indução, o processamento computacional no software WEKA não conseguiu ser realizado na imagem completa, pois demorou algumas horas sem resultado satisfatório. Para o referido teste, uma pequena amostra da imagem foi recortada e comparada a mesma parcela processada no software ENVI.



Figura 8 - Imagem Infravermelha




Figura 9 - Modelo Digital de Superfície Normalizado (MDSn)

4. RESULTADOS.

4.1 SVM

No SVM teve um resultado satisfatório, considerando que poucos dados de treinamento foram inseridos. Para o tamanho da imagem e quantidade de elementos existentes, seria importante uma quantidade muito maior de amostras, mesmo assim o resultado foi satisfatório.




Figura 7 - Resultado do SVM




Figura 8 - Ortofoto

A figura 7 apresenta o resultado do SVM e a figura 8 a ortofoto original para conferir os resultados.

4.2 Árvores de Decisão

Na árvore de decisão inicialmente foi gerado o NDVI da imagem infravermelha. O NDVI gera valores abaixo de 0 para indicações de vegetação. A árvore foi iniciada com o NDVI numa amostra de treinamento.

As condições para os valores do NDVI maior que zero foram:

- SE NDVI maior que 0.00 ENTÃO não é vegetação;
- SE não é vegetação, ENTÃO pode ser asfalto, grama ou edificação;
- SE MDSn for maior que 2 ENTÃO edificação, SENÃO asfalto ou grama;
- SE NDVI maior que 0.5 é água, SENÃO asfalto.
- E para o NDVI menor que zero as condições foram:
- SE NDVI menor que 0.00 ENTÃO é vegetação;
- SE for vegetação, ENTÃO pode ser grama ou árvore;
- SE MDSn for maior que 1 ENTÃO árvore, SENÃO grama;

O resultado da árvore está apresentado na figura 10.

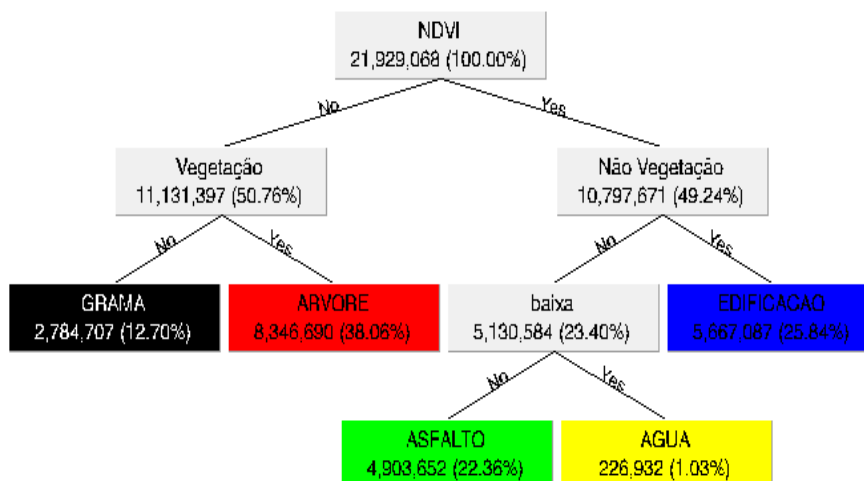


Figura 10 - Árvore de Decisão

Na figura 9 foi apresentada a imagem MSN modelo digital de superfície normalizado. Este modelo pode ser obtido de duas maneiras: uma realizando a operação matemática a partir das imagens referentes ao modelo digital de superfície e o modelo digital de terreno e a outra maneira é realizando a operação de alturas a partir dos pontos classificados, ou seja, a partir dos dados de terreno, obter as alturas dos pontos ao invés das cotas. Os valores variaram de 0 a 55 metros, onde os valores mais baixos representam os elementos com as cotas mais baixas e os valores mais altos, as feições com cotas mais altas. Como não existe retorno do laser na água, nessa área os pontos parecem interpolados.

O NDVI variou de -0.65 a 0.89 em 219290 pixels. Os valores mais baixos, ou melhor, negativos, representam um maior índice de vegetação e os valores positivos são referentes aos outros elementos, conforme apresentado na figura 11.

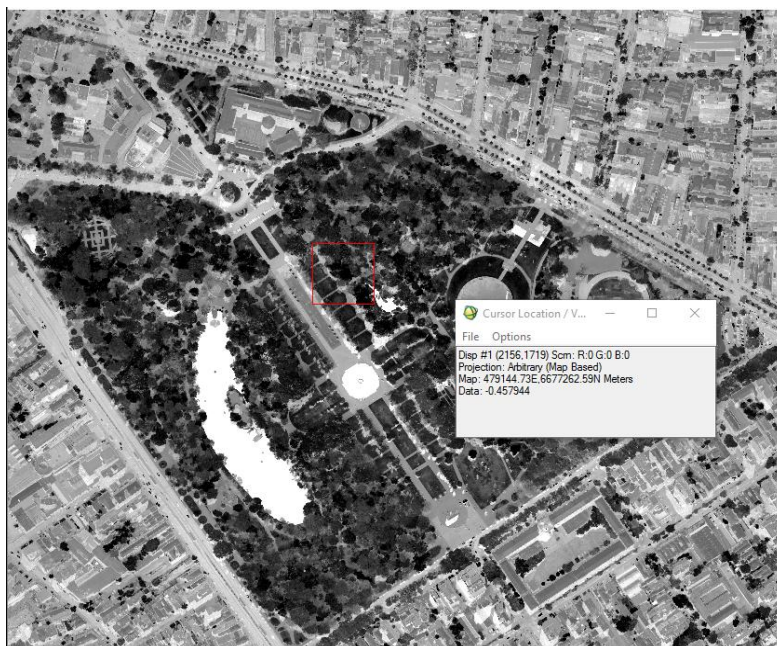


Figura 11 - NDVI

E na figura 12 está apresentado o resultado gerado pelo sistema de regras. O resultado foi satisfatório em uma parte considerável. A região de água não conseguiu ser bem classificada por causa da falta de informação do laser.




Figura 11 - Classificação da imagem por Árvore de Decisão

5 CONCLUSÃO

Na comparação entre os algoritmos SVM e Árvores de decisão, notou-se que ambos possuem vantagens e desvantagens. Uma vantagem no SVM é que é necessária apenas a imagem a imagem RGB, ou seja, nesses casos quando eu não tenho outro dado, é uma boa solução. Apresenta um grande número de acertos, se apresentando como uma ferramenta poderosa. A desvantagem é a quantidade de amostras de treinamento que precisa ser suficiente para uma boa classificação. Nas árvores de decisão, o algoritmo funcionou bem e apresentou alguns problemas devido ao ângulo de projeção das imagens que quando comparado ao MDSn que não encontra seu valor correto. Outro problema foram as áreas que possuem água tiveram seus cálculos equivocados.

Comparando com outros tipos de classificadores e considerando que o método de classificação por árvore de decisão é não paramétrico, obtive seu maior êxito no quesito tempo de processamento, com seu baixo custo computacional foi 50% mais rápido que o outro algoritmo, porém o SVM é ainda mais eficiente.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, S.; Support Vector Machines for Pattern Classifications. **Kobe**, Japão: Ed. Springer, 2005

ANDREOLA, R., HAERTEL, V., Support Vector Machines na Classificação de Imagens Hiperespectrais. In: **Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, 14, 2009, Natal. Anais... São José dos Campos: INPE, 2009. Artigos, p.6757-6764.

BURGES, C. A tutorial on support vector machines for pattern recognition. **Kluwer Academic Publisher**, Boston, 1994

LILLESAND, T.M. AND R.W. KIEFER, **Remote Sensing and Photo Interpretation**, 3rd. ed. John Wiley & Sons: New York. 750 p, 1994.

LIMA, C. A. M.; COELHO, A. L. V.; VILLANUEVA, W. J. P.; VON ZUBEN, F. J. GATED, Mixtures of Least Squares Support Vector Machine Experts Applied to Classification Problems. **Proceedings of the 5th International Conference on Recent Advances in Soft Computing (RASC2004)**, Nottingham, United Kingdom, pp. 494-499, 2004.

PEREIRA, G., CENTENO, J.A.. Utilização de Support Vector Machine para classificação multiclases de imagens Landsat TM, **Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, 2013.

VAPNIK, V. Support Vector Networks. **Kluwer Academic Publisher**, Boston, 1995.

ZHOU, Z. H.; WU, J.; TANG, W. Ensembling Neural Networks: Many Could Be Better Than All. **Artificial Intelligence**, vol. 137, no 1-2, pp. 239-263, 2002.