

III Workshop de Visão Computacional

22 a 24 de Outubro de 2007
UNESP - IBILCE – São José do Rio Preto



WVC' 2007

ANAIS



UNESP – Campus de São José do Rio Preto
Departamento de Ciência de Computação e Estatística

2007

DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO E ESTATÍSTICA - IBILCE - UNESP



WVC'2007



ISBN: 978-85-61152-00-0

III Workshop de Visão Computacional
22 a 24 de outubro de 2007
UNESP - São José do Rio Preto

Seleção Automática de Componentes de Cor para Segmentação de Imagens

Henrique de Souza Ruiz
Engenharia Elétrica, Universidade de São Paulo
Departamento de Engenharia Elétrica, EESC-USP
Av Trabalhador São-carlense, 400 - 13566-590 - São Carlos, SP, Brasil
henriquesruiz@superig.com.br

Lúcio André de Castro Jorge
Embrapa Instrumentação Agropecuária
Rua 15 de Novembro, 1452, C.P. 741, 13560-970, São Carlos, SP - Brasil
lucio@cnpdia.embrapa.br

Ednaldo José Ferreira
Embrapa Instrumentação Agropecuária
Rua 15 de Novembro, 1452, C.P. 741, 13560-970, São Carlos, SP - Brasil
ednaldo@cnpdia.embrapa.br

Adilson Gonzaga
Departamento de Engenharia Elétrica, EESC-USP
Av Trabalhador São-carlense, 400 - 13566-590 - São Carlos, SP, Brasil
agonzaga@sc.usp.br

Abstract

The choice of a color model is of great importance for many computer vision algorithms. As there are many color models available, the inherent difficulty is how to automatically select a single color model or, alternatively, a subset of color components for producing the best result for a particular task. To achieve proper colors components selection, in this paper, it is proposed the use of the wrapper method, a data mining approach, to obtain repeatability and distinctiveness in color segmentation process. The result yields good feature discrimination. The method was verified experimentally with 108 images from Amsterdam Library of Objects Images (ALOI) and 10 aerial images for different photometric conditions. Further, it is shown that the color component selection scheme provides a proper balance between color invariance (repeatability) and discriminative power (distinctiveness).

1. Introdução

A seleção de características em uma imagem é de grande importância para sistemas de visão computacional. Uma grande quantidade de informações presentes em uma imagem, como por exemplo, a cor, a textura e a forma, podem ser ou não relevantes para o processo de segmentação. A cor é uma das características mais óbvias e importantes da percepção, sendo um atributo de sensação visual, devido à interação de três componentes: fontes de luz, objeto e o sistema de visão [1].

Trabalhar com imagens coloridas, implica em escolher o sistema de cores mais adequado ou uma combinação dos mesmos. O uso de diversos modelos de cores é uma tarefa complexa para os algoritmos de visão computacional, pois o espaço de cor pode ser interpretado e modelado de diferentes formas. Nestes casos, combinar os espaços de cores ou os canais de cores ou mesmo achar a melhor combinação desses espaços para uma determinada aplicação é um grande desafio. É possível que diversos espaços de cores sejam bons candidatos no processo de segmentação ou classificação, pois podem possuir propriedades similares, como por exemplo, os canais V e G que trazem informações sobre intensidade da cor verde.

Neste artigo, o principal objetivo foi selecionar as componentes mais significativas dentre 4 modelos de cores adotados para segmentação de imagens coloridas com diferentes condições fotométricas.

A escolha das componentes de cores é de extrema importância, pois a grande dificuldade é selecionar automaticamente um subconjunto ótimo de componentes de cores e suas características mais representativas, produzindo o melhor resultado para determinada aplicação, o que é conseguido através do balanço adequado entre cores invariantes (repetibilidade) e variantes (poder discriminatório) [2].

Baseando-se na noção de separabilidade de classes, foi proposto um método para selecionar um subconjunto de componentes de cores visando alcançar a melhor seleção de características dos modelos envolvidos neste trabalho, utilizando ferramentas descritas em [3], [4] e [5].

2. Conjunto de Imagens

Para se obter a seleção das componentes de cor foram definidos, inicialmente, dois conjuntos de imagens: o primeiro com imagens artificiais obtidas em condições controladas; e o segundo com imagens de uma aplicação real.

O primeiro conjunto é formado por 108 imagens de tamanho 192x144 pixels do objeto 25 da biblioteca de imagens da Universidade de Amsterdã (Amsterdam Library of Objects Images) (ALOI) [6]. Essas imagens foram capturadas em diversas condições de iluminação, rotação e temperatura de cor. Exemplos podem ser observados na Figura 1:




Figura 1: Objeto 25 da Biblioteca ALOI, apresentando variações na temperatura de cor, iluminação e rotação.

O segundo conjunto é formado por 10 imagens aéreas de 372x248 pixels que foram adquiridas a 100 metros de altura em diferentes posições e condições de iluminação. Na Figura 2 são apresentadas imagens de fazendas de citrus utilizadas na aplicação real.




Figura 2: Imagens aéreas de fazendas de citrus.

3. Seleção de componentes de cor

A qualidade da classificação e segmentação das imagens, induzida por um algoritmo de aprendizado de máquina (*AM*) depende da relevância das características consideradas no conjunto de padrões de treinamento, chamado de vetor de características (*VC*). A relevância das características é fundamental para o algoritmo de *AM* no aprendizado de conceitos. Quanto maior a quantidade de características que não permitem a discriminação das classes, maior a necessidade de exemplos de treinamento para alcançar uma dada acurácia [7].

Os métodos de seleção de características têm a missão de encontrar uma combinação adequada de características relevantes para o aprendizado de um conceito. Várias razões justificam e motivam a aplicação da seleção de características. A primeira razão é que alguns algoritmos de *AM* computacionalmente viáveis não trabalham adequadamente na presença de um grande número de características, principalmente se houver características irrelevantes. Isso significa que a seleção pode aumentar a acurácia dos classificadores gerados por esses algoritmos. Outra razão é que a seleção pode auxiliar na compreensão dos dados. A terceira razão é que a seleção pode ajudar a reduzir os custos envolvidos na coleta de dados de alguns domínios.

A abordagem de seleção utilizada neste trabalho, conhecida como *Wrapper* [4], é apresentada na Figura 3. O método *Wrapper* é reconhecido como uma alternativa de seleção de características em problemas de aprendizado supervisionado e é caracterizado fundamentalmente por empregar os algoritmos de *AM* para avaliar os subconjuntos de características selecionados durante o processo de busca. Embora o elevado número de características faça a abordagem *Wrapper* apresentar elevado custo computacional, principalmente se a busca for exaustiva, a seleção de características relevantes para o algoritmo de aprendizado neste tipo de abordagem, supera o de outras técnicas de seleção e, por essa razão, é o foco deste trabalho.

Neste trabalho, o método *Wrapper* foi implementado usando pacotes da ferramenta *Weka*. O *Weka* é uma coleção de ferramentas de pré-processamento de dados e aprendizagem de máquina. Ela foi desenvolvida na universidade de Waikato, Nova Zelândia, em Java sob termos de licença do GNU General Public Licence [3].

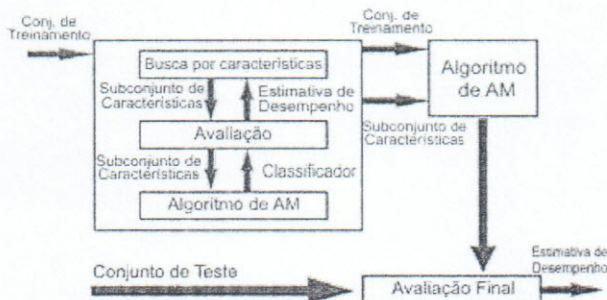


Figura 3: Método *Wrapper* para seleção de subconjunto de características [4].

A proposta desse artigo foi avaliar o desempenho de segmentação após a seleção de características por meio do método *Wrapper* com algoritmo C4.5 e busca exaustiva [3], assim como, identificar o melhor subconjunto de componentes de cor dos modelos envolvidos, gerando limiares ótimos para a classificação das classes através de árvores de decisão. O algoritmo C4.5 implementa um classificador simbólico como estrutura de árvore, onde cada nó interno indica o teste em um atributo, cada ramo representa um resultado do teste, e os nós terminais representam classes ou distribuições das classes [8].

4. Processo de segmentação das imagens nos experimentos

Neste artigo, foram utilizados 4 modelos de cores, RGB, HSV, CIE L*a*b* e I₁I₂I₃ [14]. Os modelos HSV, CIE L*a*b* e I₁I₂I₃, foram obtidos a partir de transformações do modelo RGB.

Esses modelos, tipicamente encontrados na literatura, contêm algumas propriedades variantes e invariantes no que diz respeito às condições fotométricas. As componentes de cor RGB, CIE L*, e SV são sensíveis às sombras, iluminação e brilho, ou seja, possuem um grande poder discriminatório. Já as componentes CIE a*b* e H são invariantes às sombras e intensidade da iluminação, possuindo grande capacidade de repetibilidade [9]. Para o método proposto deve haver um balanço entre o poder discriminatório e a repetibilidade.

Foram realizados três experimentos, descritos a seguir.

O primeiro experimento foi conduzido com 4 imagens do objeto 25 da biblioteca de imagens da Universidade do Amsterdã (ALOI) [6]. Este objeto é uma bola com as cores vermelho, azul, verde, amarelo e um fundo escuro,

em diferentes condições de iluminação, rotação e temperatura de cor.

Para a execução do método *Wrapper*, foi necessário capturar amostras dos padrões de cada classe presente nas imagens. As classes foram definidas por regiões *r* de cores diferentes, ou seja, vermelho, azul, verde, amarelo e o fundo. Foram capturadas 5 amostras de tamanho 3x3 de cada região, procurando contemplar as diversas condições de iluminação e brilho na seleção, como mostrado na Figura 4.




Figura 4: Seleção das amostras para uma classe verde sobre a imagem.

Para cada região *r* da imagem, foi tomada uma amostra do padrão de tamanho IxJ.. Para cada uma das componentes de cor calculou-se a média, variância e entropia das amostras *r*(*i, j*), para *i*=1...I, *j*=1...J, como mostrado nas equações (1), (2) e (3). A entropia foi determinada pelo histograma *h*(*k*) onde *v*(*h*(*k*)) são as ocorrências dos valores e *k* é o nível de cinza em cada região *r*(*i, j*); considerando cada componente uma nova imagem em tons de cinza.

$$Média = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N r(i, j) \tag{1}$$

$$Variância = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (r(i, j) - Média_{ij})^2 \tag{2}$$

$$Entropia = \sum_{k=0}^{255} h(k) * v(h(k)) \tag{3}$$

Depois de extraídos os valores da média, variância e entropia, o vetor de características *VC* foi arranjado conforme na seqüência:

$VC = [MédiaR, MédiaG, MédiaB, VariânciaR, VariânciaG, VariânciaB, EntropiaR, EntropiaG, EntropiaB, MédiaL, Médiaa, Médiab, VariânciaL, Variânciaa, Variânciab, EntropiaL, Entropiaa, Entropiab, MédiaI1, MédiaI2, MédiaI3, VariânciaI1, VariânciaI2, VariânciaI3, EntropiaI1, EntropiaI2, EntropiaI3, MédiaH, MédiaS, MédiaV, VariânciaH, VariânciaS, VariânciaV, EntropiaH, EntropiaS, EntropiaV].$

Após a criação do vetor de características VC , o método *Wrapper* com a busca exaustiva foi aplicado para selecionar o melhor subconjunto de características. Para avaliar o desempenho do subconjunto selecionado, as imagens de teste foram segmentadas utilizando as componentes selecionadas pelo *Wrapper* e a árvore gerada pelo algoritmo C4.5.

O segundo experimento foi realizado com um conjunto de imagens aéreas de fazendas de citruses, com o objetivo de identificar e gerenciar a qualidade da área cultivada. A segmentação dessas imagens poderá ser usada para identificar diferenças relativas ao vigor da cultura, às pragas, às doenças e ao nível de desenvolvimento da planta. Esse tipo de aplicação é particularmente interessante porque não é possível controlar a luz, as sombras e os reflexos do sol das imagens obtidas. Como na primeira experiência, os padrões de teste das amostras da região foram extraídos, porém usando seleções de tamanho diferentes, como mostrado na Figura 5. As classes selecionadas como padrão no teste, são: árvore de citruses, solo descoberto e ervas daninhas ou invasoras.



Figura 5: Seleção de amostras de tamanhos diferentes para o treinamento dos padrões: árvore de citruses, solo descoberto e ervas daninhas ou invasoras.

Como no primeiro experimento, para cada região r da imagem, é tomada uma amostra do padrão de cor de tamanho (I, J) . Para cada uma destas componentes de cor calcula-se a média, variância e entropia das amostras $r(i, j)$, para $i=1...I, j=1...J$, como mostrado nas equações (1), (2) e (3). Novamente, o vetor VC foi arranjado para a tarefa de seleção de características, conforme o experimento anterior.

Finalmente, um experimento foi realizado visando a comparação dos métodos propostos neste trabalho com a segmentação das imagens por redes neurais. As mesmas

amostras do treinamento da primeira e da segunda experiência foram aplicadas para o treinamento de uma rede neural *MLP (Perceptron de Múltiplas Camadas)* treinada pelo algoritmo *Backpropagation* [10], utilizando somente as médias RGB como vetor de características. Depois de treinada a rede neural, a segmentação foi aplicada a cada pixel, considerando sua vizinhança. O valor médio para cada pixel foi calculado por meio de uma máscara 3×3 sobre a imagem e apresentado à rede, cuja saída determina a classe que o pixel pertence.

5. Resultados e Discussões

O método *Wrapper* foi testado nos conjuntos de imagens apresentadas, em diversas condições de iluminação, rotação e temperatura de cor.

Iniciando pelo *Wrapper* com o algoritmo C4.5 por busca exaustiva, as imagens do objeto ALOI 25 foram processadas a partir das 12 médias das componentes de cores utilizadas neste trabalho. Os objetos apresentados na Figura 1, apresentam variação da temperatura de cor, reflexos pela iluminação e mudança do ponto de observação devido à rotação do objeto.

As médias das componentes selecionadas pelos métodos descritos na seção 3, foram $I3, H, L$ e V dos modelos de cores. Em uma segunda etapa, adicionou-se a variância e a entropia correspondente às componentes selecionadas $I3, H, L$ e V . Em todo o processo foi utilizada a validação cruzada em 10 desdobramentos (*10-fold-cross-validation*) nas amostras de treinamento, resultando em uma taxa de acertos de 99.62%. A árvore de decisão gerada é apresentada na Figura 6 e os resultados da segmentação podem ser observados na Figura 7.

Apesar das novas características adicionadas (variâncias e entropias), foi obtido o mesmo subconjunto das médias das componentes de cores $I3, H, L$ e V , e conseqüentemente a mesma árvore da decisão. Conforme esperado, devido às características das imagens, as variâncias e as entropias não contribuíram para uma melhor classificação.

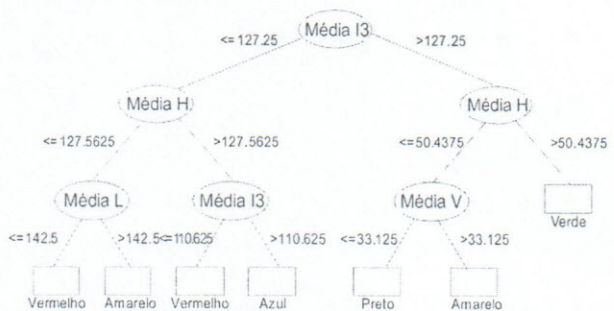


Figura 6: Árvore da decisão para o objeto 25 da Biblioteca de imagens ALOI.




Figura 7: Imagens originais do objeto 25 da Biblioteca ALOI e os resultados da segmentação das imagens baseadas no método *Wrapper* com busca exaustiva.

Outros grupos de imagens com cores similares ao objeto ALOI 25 foram testados, usando a mesma árvore da decisão gerada. Duas das imagens foram obtidas da Biblioteca ALOI e outra de uma base de imagens de partidas de futebol. O desempenho do algoritmo pode ser observado na Figura 8.




Figura 8: Imagens que não foram treinadas, utilizando a árvore de decisão mostrada na figura 6, apresentaram bom desempenho na segmentação.

No segundo experimento foi aplicada a metodologia proposta às imagens aéreas de citrus. O método *Wrapper* foi utilizado também em duas etapas, ou seja, somente com as médias em primeira instância e, posteriormente, adicionando-se as variâncias e entropias correspondentes às componentes selecionadas. A precisão em validação cruzada foi de 99.52% de acertos, sendo as componentes selecionadas, as médias de *a* e de *G*, e a entropia de *B*, como mostrado na Figura 9. Os resultados da segmentação com a árvore da decisão (Figura 9) são mostrados na Figura 10.




Figura 9: Árvore de Decisão para as imagens aéreas.




Figura 10: Imagens aéreas e os resultados da segmentação das imagens baseadas no método *Wrapper* com busca exaustiva.

Os resultados foram avaliados visualmente apenas observando-se as imagens e os respectivos segmentos. Nas imagens artificiais é fácil verificar onde a segmentação foi adequada ou não. Nas imagens aéreas, a dificuldade visual discriminatória é maior. Porém, de uma forma geral os resultados foram satisfatórios. Para comparação, foi implementada uma rede neural *MLP* (*Perceptron de Múltiplas Camadas*) com o algoritmo *Backpropagation*. Os mesmos conjuntos de treinamento utilizados no *Wrapper* foram usados para treinar a rede neural, porém, foram utilizadas apenas as componentes de médias RGB. Os resultados para os objetos ALOI 25 e as imagens aéreas podem ser observados nas Figuras 11 e 12. A rede neural foi treinada com os valores médios de RGB, apresentando um erro médio de 0.1% para o conjunto de treinamento. É possível verificar que os resultados mostraram problemas para segmentar o solo e as ervas daninhas. A idéia aqui foi avaliar um sistema de segmentação apenas com as componentes RGB uma vez que os outros sistemas de cor são derivados deste e apresentam alguma redundância. Observa-se um desempenho adequado na segmentação do objeto ALOI 25, mostrando que mesmo sob diferentes condições de iluminação, temperatura de cor e pontos de vista, é possível segmentá-las com poucas componentes de cor. No entanto, em imagens mais complexas, como as imagens aéreas de citrus, a textura é um fator importante e necessário para a discriminação das classes, além das componentes invariantes. É nesse aspecto que a seleção das componentes de cores proporcionada pela abordagem *Wrapper* se destaca, apresentando melhor desempenho mesmo com algoritmos de classificação mais simples (C4.5) comparado aos modelos tradicionais de redes neurais.



Figura 11: Segmentação das imagens das bolas usando uma Rede Neural MLP com valores médios de RGB.




Figura 12: Segmentação das imagens aéreas de citrus usando uma Rede Neural MLP com valores médios de RGB.

Convém ressaltar a existência de redundância entre algumas das componentes dos diferentes modelos de cores envolvidos neste trabalho, ainda que a combinação destas possa melhorar a precisão dos algoritmos de AM. No entanto, este trabalho mostra que a seleção adequada de um subconjunto de componentes contribui para um equilíbrio entre a capacidade de repetibilidade e poder discriminatório, o que é desejável na segmentação de imagens aéreas.

6. Conclusões

Neste trabalho, o método *Wrapper* foi proposto e aplicado de modo a selecionar um subconjunto ótimo de componentes de modelos de cores para uma discriminatória e robusta segmentação de imagens. Foi verificado experimentalmente que o método *Wrapper* usando uma busca exaustiva na seleção do subconjunto de características com Árvore de Decisão pelo algoritmo C4.5, representa uma abordagem com bons resultados de segmentação. A seleção do subconjunto de componentes de cor efetuada permitiu o balanço apropriado entre repetibilidade e o poder discriminatório.

Em Visão Computacional existe um crescente interesse na seleção de características, onde várias questões ainda permanecem abertas. Os métodos de Mineração de Dados para a seleção de características têm sido propostos com algum sucesso. Muitos exemplos destas aproximações são focalizados em clusterização numérica, não havendo nenhuma evidência teórica ou experimental relacionada a seu comportamento em imagens coloridas. Este é um dos primeiros trabalhos neste sentido. As experiências conduzidas em uma grande variedade de imagens tanto artificiais quanto reais, mostraram que o método proposto é aplicável e com resultados significativos na segmentação de imagens coloridas em diferentes condições de iluminação.

Referências

- [1] Faiechild, M. D. *Color Appearance Models*. Ed. Addison-Wesley. p. 410-421, 1998.
- [2] Stokman, H and Givers, T. *Selection and fusion of color models for image feature detection*. IEEE Trans. On Pattern analysis and Machine Intelligence. Vol. 29, n.3, march 2007.
- [3] Witten, I.H.; Frank, E. *Data Mining - Practical Machine Learning Tools and Techniques with Java*. Morgan Kaufmann Publishes, (WEKA).
- [4] Kohavi, R.; John, G. H. *Wrappers for feature subset selection*. *Artificial Intelligence*. 97(1-2):273-324, 1997.
- [5] Kohavi, R.; Sommerfield, D. *Feature subset selection using the wrapper model. Overfitting and dynamic search space topology*. In: *The First International Conference on Knowledge Discovery and Data Mining*. Pág. 192-197, 1995.
- [6] <http://staff.science.uva.nl/~aloi/>
- [7] Langley, P.; Iba, W. *Average-case analysis of a nearest neighbor algorithm*. In: *International Joint Conference on Artificial Intelligence*. Chambery, 1993.
- [8] Rezende, S. O.; Pugliesi, J. B.; Melanda, E. A.; De Paula, M. F., "Mineração de Dados", In: *Sistemas Inteligentes: Fundamentos e Aplicações*, 58 Barueri, SP, Brasil, Rezende, S. O. (coord.), Editora Manole Ltda., Cap. 12, pp. 307-336, 2003.
- [9] Gevers, T. *Color in image search engines*. University of Amsterdam. Principles of Visual Information Retrieval, Spring-Verlag, London, 2001.
- [10] Rumelhart, D.; Hinton, G; Williams, R. L. *Learning Internal Representations by Error Propagation*. In: *Parallel Distributed Processing - Vol. 1*. MIT Press, Cambridge. 1986.