

Modelo Thin-Plate Spline de Limiarização de Imagens

¹FABRICIO MARTINS LOPES
²LUÍS AUGUSTO CONSULARO

¹CEFET-PR - Centro Federal de Educação Tecnológica do Paraná
Av. Alberto Carazzai, 1640, 86300-000 Cornélio Procópio, PR, Brasil
fabricio@cp.cepro.cefetpr.br

²UEM - Universidade Estadual de Maringá
DIN - Departamento de Informática, Av. Colombo, 5790 - Bloco 019 - 87020-900 Maringá, PR, Brasil
consul@din.uem.br

1. Introdução

Modelos automáticos de limiarização de imagens levam em consideração critérios globais [1] ou aprendizado [2] para escolher um limiar (nível de cinza). Normalmente, o critério global está relacionado com características que fornecem uma noção da ordem da informação contida na imagem. Então, surge uma questão. Qual é o relacionamento entre resultados de limiarização automática e limiares subjetivos atribuídos por sujeitos humanos? Este trabalho tem por objetivo ajudar a responder esta pergunta.

2. Modelo Thin-Plate Spline de Limiarização de Imagens

Tudo começa quando um sujeito humano, para distinguir objetos e o fundo de uma imagem, define um limiar de nível de cinza, e atribui a classe fundo (ou objeto) aos pixels cujos níveis de cinza são menores que esse limiar, e a classe objeto (ou fundo) aos pixels restantes. De cada uma destas imagens armazenadas em um banco de imagens, calcula-se ainda a entropia. Então, dois conjuntos de imagens são selecionados: o conjunto de treinamento e conjunto de teste.

As entropias das imagens de treinamento, definidas no espaço real contínuo são interpoladas em relação aos limiares atribuídos pelo sujeito humano, resultando uma curva. Esta curva é parametrizada pelos pesos do vetor w obtido por um sistema linear do tipo $y = \Phi w$. Neste sistema linear, a matriz Φ é obtida pela aplicação de funções thin-plate splines [3] às distâncias entre todos os pares de entropias das imagens do conjunto de treinamento. O vetor y contém cada limiar selecionado pelo sujeito humano.

Aplica-se então os pesos do vetor w ao conjunto de teste para tentar generalizar os limiares atribuídos pelo sujeito humano. O resultado é então comparado aos limiares realmente atribuídos,

resultando um erro RMS (*Erro Médio Quadrático*). O menor erro corresponde a melhor combinação entre o conjunto de treinamento e o conjunto de teste, i.e., o melhor w .

Os resultados obtidos têm indicado que esta abordagem é bastante útil para buscas em bancos de imagens, pois conjuntos de imagens similares no treinamento proporcionam erros menores no teste. Isto se deve, principalmente à característica do atributo entropia, que mede complexidade de informação. Contudo a entropia não considera qualquer dependência espacial entre os pixels.

3. Conclusão

Este trabalho apresentou um modelo que aproxima a decisão humana ao atribuir limiares de níveis de cinza para segmentar imagens. Os testes mostraram resultados que permitem distinguir conjuntos de imagens similares. Esta abordagem serve como ponto de partida para a construção de um seletor de características relevantes aos humanos para a limiarização de imagens.

Referências

- [1] P. K. Sahoo, S. Soltani, C. Wong and Y. C. Chen, "A Survey of Thresholding Techniques", CVGIP 41(1988), 223-260.
- [2] P-Y. Yin, "Maximum entropy-based optimal threshold selection using deterministic reinforcement learning with controlled randomization", Signal Processing 92(2002), 993-1006.
- [3] F.L. Bookstein, "Principal Warps: Thin-plate Splines and the Decomposition of Deformations", IEEE TPAMI 11(6)(1989), 567-585.