

UNIVERSIDADE FEDERAL DO AMAZONAS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE APOIO À PESQUISA
PROGRAMA INSTITUCIONAL DE BOLSAS DE INICIAÇÃO
CIENTÍFICA

DETECÇÃO DE PELE EM IMAGENS DA WEB

Bolsista: Kely Maciel Braule Pinto, CNPq

MANAUS

2011

UNIVERSIDADE FEDERAL DO AMAZONAS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE APOIO À PESQUISA
PROGRAMA INSTITUCIONAL DE BOLSAS DE INICIAÇÃO
CIENTÍFICA

RELATÓRIO FINAL

PIB-E/0004/2010

DETECÇÃO DE PELE EM IMAGENS DA WEB

Bolsista: Kely Maciel Braule Pinto, CNPq

Orientador: Prof. Dr. Eduardo James Pereira Souto

MANAUS

2011

Este trabalho de pesquisa apresenta um método de detecção de pele em imagens baseado nas características mais relevantes da própria imagem. A detecção de pele é o método mais direto e eficaz na detecção de outros problemas mais complexos como reconhecimento de faces, extração de informação facial e detecção de nudez em imagens. Por isso, o propósito deste trabalho é apresentar uma metodologia que pode ser utilizada como ponto de partida para outras aplicações. Os passos que consistem na metodologia de detecção de pele são: a normalização das imagens obtidas, fazendo com que todas possuam a mesma resolução e o mesmo formato JPEG; a construção de um filtro de pele, que utilizará o espaço de cores $YCbCr$ para controle de luminosidade e segmentação da imagem em região de pele e não-pele; e, por fim, a extração de características que irão compor um vetor de características utilizado por uma máquina de aprendizagem que definirá o modelo final para sinalizar se a imagem contém ou não pele. Este trabalho adotou o classificador SVM (*Support Vector Machines*). O classificador foi treinado para realizar a detecção de pele. Foram adotadas seis características extraídas das imagens, sendo que quatro delas apresentaram resultados satisfatórios. Foram analisadas 1300 imagens. A taxa de acerto do método aplicado foi de 99%, sendo 1.287 imagens classificadas corretamente e taxa de erro de 1%, com 13 imagens classificadas erroneamente. Foram realizados estudos para descartar as características irrelevantes por que isto influencia na melhora do desempenho de classificação das amostras e, conseqüentemente, no custo para processar e extrair as evidências.

Palavras chave: Detecção de pele; Classificação; Análise de características

SUMÁRIO

1	INTRODUÇÃO	4
2	REVISÃO BIBLIOGRÁFICA	5
3	METODOLOGIA UTILIZADA.....	7
3.1.	Normalização da Imagem	7
3.2.	Segmentação da Imagem	7
3.3.	Extração de características.....	7
3.4.	Classificação	9
4	RESULTADOS E DISCUSSÕES.....	11
	Base de dados	11
	Protocolo experimental.....	11
	Métricas de desempenho.....	12
	Resultados.....	12
5	CONCLUSÕES.....	15
	REFERÊNCIAS BIBLIOGRÁFICAS.....	16
	APÊNDICE A - CRONOGRAMA EXECUTADO.....	18

1 INTRODUÇÃO

A quantidade de conteúdo visual disponível na Internet é cada vez maior o que impossibilita sua análise manual. Uma abordagem para lidar com este problema é a utilização de mecanismos de classificação que permitam a análise automática e possam impedir o acesso a conteúdos impróprios como, por exemplo, imagens contendo nudez (Sevimli *et al.* 2010).

Na literatura, diferentes métodos para filtragem de imagens de pele têm sido considerados para detecção de conteúdo impróprio. Jones e Rehg (2002) descrevem um sistema baseado em um modelo estatístico apoiado na cor da pele e em um classificador do tipo rede neural. Wang *et al.* (2009) apresentam um algoritmo de reconhecimento de nudez a partir da localização do umbigo em imagens digitais. O umbigo é usado como ponto de referência para a construção de retângulos que são usados para computar a proporção de pele. Duan *et al.* (2002) utilizaram um modelo de cor para filtrar as imagens e depois classificá-las através de máquinas de vetores suporte (SVM - *Support Vector Machines*).

Um ponto em comum a essas e outras abordagens é a utilização de um filtro de pele para a detecção de nudez. Arentz e Olstad (2004) destacam que o principal elemento para detectar nudez e a identificação de regiões de pele na imagem. De acordo com Ruiz-del-Solar e Verschae (2004), as características mais relevantes num processo de detecção de pele são: (i) o custo computacional, pois qualquer método de processamento digital de imagem requer tempo e processamento e (ii) a invariância contra oclusões parciais e mudanças de pose. Porém, o grande problema em detecção de pele é que diversos objetos do mundo real, tais como alguns tipos de couro, areia, madeira, peles de animais e objetos avermelhados possuem cores com tonalidade próximas às de pele e podem ser mal interpretados por detectores automáticos (Kelly *et al.* 2007).

Diante desse contexto, o objetivo desse trabalho é apresentar um método de detecção de pele em imagens digitais baseado nas características extraídas da própria imagem. O motivo da pesquisa é devido a sua importância para o desenvolvimento de pesquisas mais complexas, como reconhecimento de faces, extração de informação facial e detecção de nudez em imagens.

O restante deste trabalho está organizado da seguinte forma. A Seção 2 fornece uma revisão bibliográfica. A metodologia do trabalho é detalhada na Seção 3. A Seção 4 apresenta e discute os resultados obtidos através dos experimentos realizados. Por fim, a conclusão do trabalho é apresentada na Seção 5.

2 REVISÃO BIBLIOGRÁFICA

Nesta seção serão discutidos alguns dos modelos propostos na literatura para detecção de pele em imagens utilizada como etapa inicial em diversas outras aplicações maiores. Os trabalhos aqui relacionados são aqueles que fornecem informações sobre a base de dados e adotam a utilização de alguma técnica de aprendizagem de máquina e utilizam espaços de cores para reduzir os efeitos da luminosidade no processo de filtragem de pele.

Wang *et al.*(2009) propõem um modelo em que se utiliza primeiramente a detecção de face para representação de imagens de nudez. Posteriormente, através da combinação de espaço de cores como *YUV* e *YIQ* (*Y* representa a luminância e *UV-IQ* a cromaticidade) detectam a região de pele através de informações de cor e textura. Estas evidências são utilizadas como entrada para o classificador SVM. O conjunto de imagens é constituído de 802 imagens de nudez e 2125 imagens que não contém nudez, obtendo 89,3% de sensibilidade e 90,1% de especificidade. A sensibilidade denota a razão entre o número de imagens de nudez classificadas corretamente para o número total de imagens de nudez, enquanto que a especificidade denota a razão entre o número de imagens que não contém nudez classificadas corretamente para o número total de imagens desta classe. Entretanto, a utilização de mecanismos para detecção de face combinados com as diversas características da imagem demandam uma enorme complexidade computacional, não satisfazendo o ideal para representação um sistema *online* de detecção de nudez.

Zhu *et al.* (2007) combinam os espaços de cores *YUV* e *YIQ* para controle da luminosidade e filtragem de pele objetivando a extração de informações referentes a cor. Em seguida, informações da textura são utilizadas através da matriz de co-ocorrência e da análise da estrutura dos seres humanos. Essa combinação de características foi introduzida em um classificador SVM. São utilizadas 400 imagens de nudez e 400 imagens diversas, obtendo-se 88,9% de sensibilidade e 84,6% de especificidade. Apesar da elevada taxa de classificação, o modelo utiliza muitas informações baseadas na forma, que demandam alto esforço computacional.

Lee *et al.*(2006) apresentam um algoritmo que utiliza um filtro de pele baseado no controle de luminosidade através do espaço de cor *YCbCr*. Inicialmente, são utilizadas características de cor e formas para detecção de pele e posteriormente ocorre um processo de detecção de faces para garantir a eficiência

do modelo. Foram consideradas 508 imagens de nudez e 482 imagens que não contêm nudez. As imagens foram classificadas utilizando-se uma combinação de classificadores SVM e Redes Neurais (NN). Esse método obteve 86,7% de sensibilidade e 94,8% de especificidade. Entretanto os autores não analisam o impacto das características no classificador.

Cusano *et al.*(2003) descrevem um modelo que utiliza características de borda, textura e o espaço de cores *HSV (Hue, Saturation, Value)*, criando um vetor para classificação usando *CART (Classification on Regression Trees)* e SVM. O processo experimental consiste de 1.500 imagens, sendo 750 pornográficas e as 750 restantes sem pornografia. Os resultados alcançaram 90,4% de sensibilidade e 88,4% de especificidade. Nesse trabalho foi verificada a utilização de combinação de características de cor, textura e formas, juntamente com a combinação de classificadores, o que acarreta alto esforço computacional.

Duan *et al.*(2002) propõem um novo método de detecção de pele baseado em características da cor. Esse método primeiro rotula os *pixels* referentes à pele como exemplos de treinamento para posteriormente, converter os valores de *pixels* no espaço de cor RGB para os espaços de cores *YUV* e *YIQ*. Assim, o modelo de distribuição de pele é obtido e um vetor de características que é usado na classificação com SVM. O conjunto de teste é composto por 312 imagens contendo nudez e 710 imagens sem nudez. Esse modelo obteve 80,7% de sensibilidade e 90% de especificidade. Porém, essa abordagem utiliza apenas duas características e a quantidade de amostra é pouco representativa.

Jiao *et al.*(2001) propõem um modelo que utiliza informações de cor e bordas para criar um vetor de características para posterior classificação das imagens através do SVM. O método também usa os espaços de cores *YUV* e *YIQ*. O conjunto de teste é constituído por 1.200 imagens de pessoas e 1.200 imagens diversas, sendo que foram obtidos 89,3% de sensibilidade e 90,6% de especificidade. Porém, esse trabalho, apesar de utilizar informações de formas, analisa apenas imagens contendo nudez em que as pessoas estão em posição frontal, tornando o resultado pouco abrangente.

As características utilizadas neste trabalho foram levantadas a partir dos trabalhos aqui relacionados. É de ampla aceitação na área de aprendizagem de máquinas que a escolha das características mais relevantes determina o sucesso dos métodos de classificação. Portanto, as características levantadas serão analisadas e a melhor combinação para a aplicação proposta será escolhida.

3 METODOLOGIA UTILIZADA

A metodologia utilizada neste trabalho é composta por quatro etapas: Normalização da Imagem, Segmentação da Imagem, Extração de Características Relevantes e Classificação.




Figura 1 - Visão geral da metodologia utilizada

3.1. Normalização da Imagem

A normalização consiste em padronizar as imagens obtidas através da Internet, de forma que possuam a mesma dimensão e formato. Todas as imagens alcançadas foram uniformizadas em 64 colunas por 42 linhas em formato JPEG.

3.2. Segmentação da Imagem

O filtro de pele corresponde à segmentação das imagens em duas regiões: (1) região de pele e (2) região de não pele. O processo de segmentação das imagens foi realizado através da conversão do espaço de cores RGB para $YCbCr$, onde Y é a componente que traz informações de luminosidade da imagem, Cb e Cr trazem informações da cromaticidade. De acordo com Kelly *et al.* (2007), o uso do espaço de cores $YCbCr$ proporciona as melhores taxas de detecção de pele, além de reduzir o custo computacional. Empregando a análise de histogramas de algumas amostras, manipuladas na ferramenta Matlab (2009), foi possível encontrar os valores de pixels referentes à pele com Cb variando de 77 a 127 e Cr de 133 a 173. A partir dos valores de pixels de pele, as imagens foram segmentadas.

3.3. Extração de características

As características devem realçar semelhanças intra-classe e diferenças inter-classe. Neste trabalho são analisadas seis características, sendo duas características de cor e quatro medidas de textura.

As características de cor são extraídas das imagens segmentadas na etapa do filtro de pele da metodologia. Estas são as seguintes:

- Quantidade de *pixels* conectados: utilizando-se o espaço de cor *YCbCr*, a cor da pele, independentemente de suas variações (branca, negra, amarela, etc), tende a possuir maior conectividade em relação às imagens que não contém pele (Zeng *et al.* 2004).
- Proporção da área de pele com relação à área total da imagem: esta característica fornece informações sobre a proporção de segmentos (P_s) de pele na imagem. Sendo N_s o número de *pixels* de pele e N_t o número de *pixels* total da imagem, os segmentos de pele podem ser encontrados através da seguinte fórmula (Zeng *et al.* 2004):

$$P_s = \frac{N_s}{N_t} \quad (1)$$

Já as características de textura são extraídas a partir de uma *Gray-Level Co-occurrence Matrix* (GLCM), ou matriz de co-ocorrência. Uma GLCM representa a probabilidade de ocorrência de conjuntos de níveis de cinza em i e j dentro de uma relação espacial definida na imagem, sendo i e j os índices de linha e de coluna da matriz vizinhança. Essa relação espacial é definida em termos de uma distância d e um ângulo θ . Assim, dado uma GLCM, alguns dados estatísticos podem ser extraídos, tais como: contraste, correlação, energia e homogeneidade. Considerando tais dados estatísticos, este trabalho encontrou a melhor distância para $d = 1$, calculada em 8 direções e $\theta = [0, 45, 90, 135, 180, 225, 270, 315]$. Logo, o vetor de características de textura é composto por 32 componentes. As quatro métricas listadas abaixo, conforme Zeng *et al.* (2004):

- Contraste: retorna uma medida do contraste entre as intensidades de um *pixel* analisado e do *pixel* vizinho. A comparação é realizada em todos os *pixels* da imagem. Para uma imagem contraste, o contraste é 0 (zero).

$$Con = \sum_{ij} P(i - j)^2 p(i, j) \quad (2)$$

- Correlação: retorna uma medida de quão correlacionado está um *pixel* com seu vizinho. A comparação é realizada em todos os *pixels* da imagem. A correlação é 1 para uma imagem totalmente correlacionada.

$$Corr = \sum_{ij} \frac{(i - \mu_i)(j - \mu_j) p(i, j)}{\sigma_i \sigma_j} \quad (3)$$

- Energia: retorna a soma dos elementos elevados ao quadrado dentro da matriz de co-ocorrência de tons de cinza. A energia possui valor 1 para uma imagem constante.

$$Enrg = \sum_{ij} p(i,j)^2 \quad (4)$$

- Homogeneidade: retorna um valor que representa a proximidade da distribuição dos elementos em relação à diagonal da matriz de co-ocorrência dos tons de cinza.

$$Hmg = \sum_{ij} \frac{p(i,j)}{1+(i-j)} \quad (5)$$

3.4. Classificação

A partir da leitura do vetor de características, o classificador tem o papel de definir se a imagem pertence à classe pele ou à classe não-pele. Neste trabalho foi utilizado o classificador SVM por apresentar resultados animadores em problemas de detecção de pele (Kelly *et al.* 2007). O processo de treinamento e teste do classificador foi realizado através do ambiente Weka (2010).

SVM é uma técnica de classificação amplamente aplicada em problemas de segurança de redes tais como classificação de sites ofensivos (Belém *et al.* 2005) e detecção de intrusos (Xiao *et al.* 2007). Basicamente, o funcionamento do SVM pode ser descrito da seguinte forma: dadas duas classes e o conjunto de treinamento cujas amostras pertencem a essas classes, SVM divide o espaço de características em duas regiões através da construção do hiperplano de separação ótima. Trata-se de um hiperplano que divide as classes maximizando a margem de separação entre elas. As amostras desconhecidas (exemplos de teste) são então mapeadas para esse mesmo espaço, e atribuídos a uma das classes (Alpaydim 2004).




Figura 2 - Hiperplano de separação ótima

A Figura 1 mostra o hiperplano de separação ótima (reta separadora) para um problema bidimensional típico e linearmente separável. As retas pontilhadas H_1 e H_2 , paralelas ao hiperplano, constituem o par de hiperplanos que geram a margem máxima pela minimização do vetor peso w . Além disso, $|b|/||w||$ é a distância perpendicular do hiperplano à origem e $||w||$ é a norma Euclidiana de w . Os pontos que estão em um dos hiperplanos H_1 e H_2 são chamados vetores de suporte. Esses pontos, indicados na Figura 1 por círculos extras, alteram a solução encontrada caso sejam removidos.

O algoritmo original de SVM não encontra a solução desejada quando aplicado a dados não linearmente separáveis, característica presente na maioria dos problemas reais (Alpaydim 2004). Tais problemas são solucionados através da utilização de funções mais complexas que funções lineares. As funções *Kernel* permitem que SVM encontre superfícies de separação em problemas não linearmente separáveis. Sendo assim, o uso de diferentes funções *Kernel* possibilita a construção de SVM com diferentes tipos de superfícies de decisão não-linear no espaço de entrada. As funções *Kernel* mais utilizadas são polinomial e função RBF (Função de Base Radial). Mais detalhes sobre SVM podem ser obtidos em Burges (1998).

4 RESULTADOS E DISCUSSÕES

Esta seção detalha as características investigadas neste artigo e apresenta a descrição da base de dados, métricas utilizadas, juntamente com a análise do impacto das características investigadas.

Base de dados

Para realizar os experimentos foi utilizada uma base de imagens composta por 2100 imagens coletadas do repositório de dados da Caltech (2005). Foram selecionadas 550 imagens de amostras da classe pele (pessoas de várias etnias: caucasianos, africanos e asiáticos) e 1550 imagens da classe neutra (ambientes diversos, carros motos, aviões, etc). Todas as imagens são coloridas e conforme citado na seção 3.1., foram normalizadas, estando dispostas em formato JPEG.

Protocolo experimental

Para análise de desempenho das características, a base de imagens foi dividida em base de treinamento e base de teste. A base de treinamento foi composta por 800 imagens, sendo 400 imagens de pele e 400 de imagens neutras, totalizando 40% do conjunto inicial de imagens. A base de teste foi constituída por 1300 imagens, sendo 150 imagens de pele e 1150 imagens neutras, totalizando 60% do conjunto inicial de imagens.

Foram realizados alguns ajustes de parâmetros durante a fase de treinamento. Para este fim, foi utilizada a estratégia de validação cruzada que atua da seguinte forma: o conjunto de treinamento é dividido em n subgrupos de igual tamanho. A cada interação, $n-1$ conjuntos são combinados para compor o conjunto de treino, enquanto que o subgrupo restante é usado como base de validação. Esse processo é repetido n vezes. No fim, a média de classificação obtida nas n bases de validação é calculada, sendo que os parâmetros que apresentam os melhores resultados são usados para calcular a capacidade de generalização sobre a base de teste.

O SVM foi usado no processo de classificação. Os resultados da validação cruzada indicam que o *kernel* RBF superou o *kernel* polinomial. Além do tipo de *kernel*, há a necessidade de ajuste do parâmetro de penalização C e do

parâmetro γ , definido para o kernel RBF. Nestes experimentos, esses parâmetros foram divididos em $C = 6$ e $\gamma = 0,05$.

Métricas de desempenho

Existem diversas métricas na literatura para avaliar o desempenho de um sistema de classificação. Este trabalho adota as métricas propostas por Wang *et al.*(2009) que são utilizadas na maioria dos trabalhos descritos na seção 2. Essas métricas são definidas abaixo:

- Especificidade: definida como a razão entre o número de imagens neutras corretamente classificadas para o número total de imagens neutras.
- Sensitividade: definida como a razão entre o número de imagens de pele classificadas corretamente para o número total de imagens de pele.
- Taxa de acertos: calculada através da razão entre o conjunto total de imagens classificadas corretamente (pele e neutras) para o conjunto total de imagens.
- Taxa de erro: calculada através da razão entre o conjunto total de imagens classificadas incorretamente (pele e neutras) para o conjunto total de imagens.

Resultados

A análise do impacto das características está dividida em duas partes. Na primeira, as características são avaliadas por grupo, isto é, características de cor e de textura são aplicadas separadamente. Na segunda parte, as características dos dois grupos são avaliadas.

A tabela 1 mostra os resultados obtidos por SVM treinado com as duas características de cor. Foram obtidos 55,3% de sensibilidade, sendo 83 imagens de pele classificadas corretamente e, 90,1% de especificidade, ou seja, 1043 imagens neutras classificadas corretamente. A taxa de acerto foi de 86,7%, totalizando 1.126 imagens classificadas corretamente e erro de 13,3%, com 174 imagens classificadas incorretamente. A análise isolada das duas características de cor mostrou-se irrelevante, pois ambas são totalmente dependentes. A partir da quantidade de *pixels* de pele conectados é calculada a porcentagem de pele na imagem. Assim, usando apenas uma característica isoladamente, o classificador não aprende e tende a classificar as amostras como pertencentes à classe neutra.

Os resultados das avaliações isoladas de cada característica e da combinação (quantidade e porcentagem de pele juntas) são exibidos abaixo.

	Quantidade de pele		Porcentagem de pele		Combinação	
	Pele	Neutras	Pele	Neutras	Pele	Neutras
	Pele	37,2%	62,8%	29,4%	70,6%	55,3%
Neutras	18,6%	81,4%	16,3%	83,7%	9,9%	90,1%

Tabela 1 - Matriz de confusão e análise de características de cor a partir das taxas obtidas pelo classificador SVM

Ao analisar o conjunto de características de textura, diversas combinações foram realizadas a fim de encontrar o conjunto mais relevante. Foram verificados que a combinação de homogeneidade e correlação produziu os melhores resultados.

Essa combinação obteve 92% de sensibilidade, sendo 138 imagens de pele classificadas corretamente e 99,7% de especificidade, com 1.147 imagens neutras classificadas corretamente. A taxa de acertos foi de 98,8%, totalizando 1.285 imagens classificadas corretamente e erro de 1,2% com 15 imagens classificadas erroneamente. A tabela 2 apresenta os resultados da análise das características de textura.

	Homogeneidade		Correlação		Contraste		Energia		Homogeneidade + Correlação	
	Pele	Neutras	Pele	Neutras	Pele	Neutras	Pele	Neutras	Pele	Neutras
	Pele	88,0%	12,0%	82,7%	17,3%	0%	100%	92,6%	7,4%	92,0%
Neutras	0,8%	99,2%	1,4%	98,6%	0%	100%	0,7%	99,3%	0,3%	99,7%

Tabela 2 - Matriz de confusão obtida através do classificador SVM e impacto das características de textura

Por fim, todas as características de cor e textura foram combinadas. A Tabela 3 apresenta os resultados da análise de combinação de todas as 6 características e a melhor combinação resultante. As melhores características resultantes das análises realizadas para cada grupo separadamente, foram combinadas para verificação do desempenho do classificador. Os resultados mostram que a combinação das duas características de cor, mais as duas melhores características de textura, ou seja, homogeneidade e correlação, levou SVM a obter 94,7% de sensibilidade, totalizando 142 imagens de pele classificadas corretamente e 99,6% de especificidade, com 1.145 imagens neutras classificadas

corretamente. A taxa de acertos foi de 99%, sendo 1.287 imagens classificadas corretamente e erro de 1%, com 13 imagens classificadas erroneamente.

	Todas as 6 características		Melhor Combinação	
	Pele	Neutras	Pele	Neutras
Pele	94,0%	6,0%	94,7%	5,3%
Neutra	0,4%	99,6%	0,4%	99,6%

Tabela 3 - Matriz de confusão obtida pelo classificador SVM e análise da melhor combinação de todas as características na base de teste

Vale ressaltar que, apesar de alguns trabalhos disponibilizarem informações importantes sobre a composição da base de dados, como etnia, quantidade de amostras e condições de luminosidade, um processo de comparação justa e direta é inviável, devido à inexistência de bases de dados de *benchmarking*.

Um ponto importante a ser destacado é que as imagens neutras, que foram classificadas como pele, apresentavam muitos *pixels* de cor amarela e vermelha. Uma análise detalhada revelou que a maioria dessas imagens correspondia a imagens que contém areia ou alguma formação rochosa. Os resultados também confirmam que o descarte de características irrelevantes melhora o desempenho de classificação das amostras e, conseqüentemente, o custo para processar e extrair as evidências. A combinação das características mais relevantes, identificadas neste trabalho, pode ser adotada por diversos trabalhos futuros.

5 CONCLUSÕES

Este trabalho apresentou uma metodologia para detecção de pele em imagens. Foram feitas análises em seis características para a classificação automática de imagens de pele. O impacto de cada característica foi medido em função da taxa de classificação do SVM.

A principal contribuição deste trabalho foi a montagem de uma metodologia básica para aplicações mais complexas onde é necessário a detecção de pele. Evidenciaram-se as características mais relevantes com o objetivo de reduzir a dimensionalidade do espaço de características, diminuindo o esforço computacional e aumentar o desempenho da classificação das amostras.

Os resultados mostraram que a combinação de duas características de cor, isto é, quantidade de *pixels* de pele conectados e proporção da área de pele com relação à área total da imagem, juntamente com duas características de textura, homogeneidade e correlação, formam o conjunto de características mais relevantes ao problema investigado.

Contribuições

Este trabalho teve como principal objetivo contribuir para o trabalho de pesquisa “Detecção de Nudez em Imagens Veiculadas na Web”. O resultado dessa pesquisa originou dois artigos: “ANÁLISE DE CARACTERÍSTICAS PARA DETECÇÃO DE PELE EM IMAGENS”, submetido ao 10th Brazilian Congress On Computational Intelligence (CBIC 2011) e “NDAImage: Uma Arquitetura para Detecção de Nudez em imagens”, submetido ao XI Simpósio Brasileiro em Segurança da Informação e de Sistemas Computacionais (XI SBSEG 2011).

REFERÊNCIAS BIBLIOGRÁFICAS

AL PAYDIM, E. Introduction to Machine Learning. THE MIT PRESS. CAMBRIDGE MASSACHUSETTS, EUA. 415 pp.

ARENTZ, W. A.; OLSTAD, B. Classifying offensive sites based on image content (2004). In: Computer Vision and Image Understanding 94. pp 295-310.

BELÉM, R. J. S.; CALVACANTI, J. M. B. SNIF: A Simple Nude Image Finder. In: PROCEEDINGS OF THE THIRD IEEE LATIN AMERICAN WEB CONGRESS (LA-WEB'05), 2005. PP. 252-258.

BURGES, C. J. C. A tutorial on Support Vector Machines for Pattern Recognition. In: DATA MINING AND KNOWLEDGE DISCOVERY, Vol 2, 1998. PP 121-167.

CALTECH. Computational Vision Laboratory. California Institute of Technology (2005). Disponível em: <http://www.vision.caltech.edu/html-files/archive.html> . Acesso em Abril de 2010.

CUSANO, C., et al. On the Detection of pornographic digital images, VCIP, 2003. pp 2105-2113.

DUAN, L., et al. Adult Image Detection Method Base-on Skin Color Model And Support Vector Machine. In: ACCV, 2002, Melbourne, Australia. pp 22-25.

JIAO, F., et al. Detecting Adult Image using Multiple Features. In: INTERNATIONAL CONFERENCE INFO-TECH AND INFO-NET, 2001. pp 378-385.

JONES, M. J.; REHG, J. M. Statical Color Models with Application to Skin Detection. COMPUTER VISION, vol. 46, 2002. pp 81-86.

KELLY, W.; DONNELLAN, A.; MOLLOY, D. A Review of Skin Detection for Objectonable Images. In: ITT, 2007. Proceedings. pp. 310-319.

LEE, J. S., et al. Naked image detection based on adaptive and extensible skin colour model. PATTERN RECOGNITION, Vol.40, 2006. pp 2261-2270.

MATLAB.The Language Of Technical Computing, THE MATHWORKS, 2009. Disponível em: <http://www.mathworks.com>. Acesso em: Junho de 2010.

RUIZ-DEL-SOLAR, J.; VERSCHAE, R. Skin Detection using Neighborhood Information. In: AUTOMATIC FACE AND GESTURE RECOGNITION, 2004. PROCEEDINGS. SIXTH IEEE INTERNATIONAL CONFERENCE ON, 2004. pp 463-468.

SEVIMLI, H. et al. Adult Image Content Classification Using Global Features and Skin Region Detection. In: PROCEEDINGS OF THE 25th INTERNATIONAL SYMPOSIUM ON COMPUTER AND INFORMATION SCIENCES (ISCIS), 2010. pp 253-258.

XIAO, H.; HONG, F.; ZHANG, Z.; LIAO, J. Intrusion Detection Using Ensemble of SVM Classifier. In: FOURTH INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY (FKSD 2007), 2007. pp 45-49.

WANG, J.; Li, J.; WIEDERHOLD; FIRSCHEIN, G. System for Screening objectionable Images COMPUTER COMMUNICATIONS, 1998. pp. 20-30.

WANG, X.; HU, C.; YAO, S. An Adult Image Recognizing Algorithm on Naked Body Detection. In: IEEE INTERNATIONAL COLLOQUIUM ON COMPUTING COMMUNICATION, CONTROL AND MANAGEMENT, 2009. pp. 197-200.

WEKA. Data Mining with Open Source Machine Learning Software in Java, 2010. University of Waikato. Disponível em: <http://www.cs.waikato.ac.nz/~ml/weka>. Acesso em Outubro de 2010.

ZENG, Z., et al. Blocking Adult Images Based on Statistical Skin Detection, In: ELECTRONIC LETTERS ON COMPUTER VISION AND IMAGE ANALYSIS, Vol. 4 2004. pp 1-14.

ZHU, H. An Algorithm of Pornographic Image Detection. In: FOURTH INTERNATIONAL CONFERENCE ON IMAGE AND GRAPHICS, 07, 2007. pp. 801-804.

