

Análise de Características para Detecção de Nudez em Imagens

Clayton Santos, Eulanda M. dos Santos, Eduardo Souto

Instituto de Computação (IComp) – Universidade Federal do Amazonas (UFAM),
{clayton.maia, emsantos, esouto}@icomp.ufam.edu.br

Resumo— Esta dissertação objetiva investigar as principais características usadas na literatura para descrever imagens de nudez e selecionar as características mais relevantes em função da precisão do classificador. A análise das características é feita através de um conjunto de séries de experimentos que representam diferentes cenários de comparação, utilizando propriedades globais e locais e, posteriormente um algoritmo de zoneamento é utilizado para que seja analisado o impacto das características, tanto locais como globais, em cada zona da imagem. É utilizada ainda uma arquitetura denominada ANDImage (Architecture for Nude Detection in Image), que permite a inclusão e exclusão de diferentes módulos.

Palavras-chave- imagens; detecção de nudez; análise de características.

Abstract—The objective of this work is to investigate the features most frequently used in the literature for the description of nude images, as well as to select the most relevant subset of features taking into account classification accuracy. The feature analysis is carried out through three series of experiments focusing on investigating different scenarios of comparison, using global and local properties. In addition, a zoning algorithm is used to allow the analysis of the impact of both characteristics, local and global, in each area of the image. Finally, it is used an architecture called ANDImage (Architecture for Nude Image Detection in), which allows the inclusion and exclusion of different modules.

Keywords- images; nudity detection; feature analysis.

I. INTRODUÇÃO

A *World Wide Web* é considerada um enorme centro de dados, permitindo que seus usuários no mundo todo possam compartilhar e trocar informações. Embora a *Web* proporcione muitos benefícios, também disponibiliza uma ampla variedade de conteúdos nocivos e ilegais, como por exemplo, páginas com imagens de nudez e de pornografia.

O controle de acesso inapropriado a conteúdos ofensivos é importante, dentre várias razões, por questões de segurança. Em relatório recente (2011), a Symantec [15] mostra que existe uma relação direta entre pornografia e a difusão de *malware*. De acordo com esse relatório, do total de ataques provenientes da Internet, 49% deles são feitos por meio de sites pornográficos.

Uma forma de evitar o acesso a esse tipo de conteúdo é a utilização de filtros *Web*. A detecção de nudez em imagens é considerada um passo importante no sentido de limitar a proliferação de conteúdo indesejável, como a pornografia. Na literatura, diferentes métodos para filtragem de imagens contendo nudez têm sido considerados, tais como os trabalhos de Fleck *et al.* [4], Wang *et al.* [17], Jones & Reh

[7], Wang *et al.* [18], entre outros. Neste trabalho¹, será apresentada uma abordagem de detecção de nudez que utiliza informações extraídas unicamente de imagens, por meio de técnicas de processamento digital de imagens.

É possível observar na literatura a frequente utilização de filtros de pele no processo de detecção de nudez. Arentz e Olstad [1] apontam a representação dos *pixels* de pele em um espaço de cor adequado como o principal elemento para detectar nudez. Além das informações de pele, destaca-se a combinação de informações como cor, textura e forma. Porém, embora a análise de características permita a identificação das informações mais relevantes para detectar nudez em imagens, esse tipo de análise normalmente não é feita nos trabalhos encontrados na literatura.

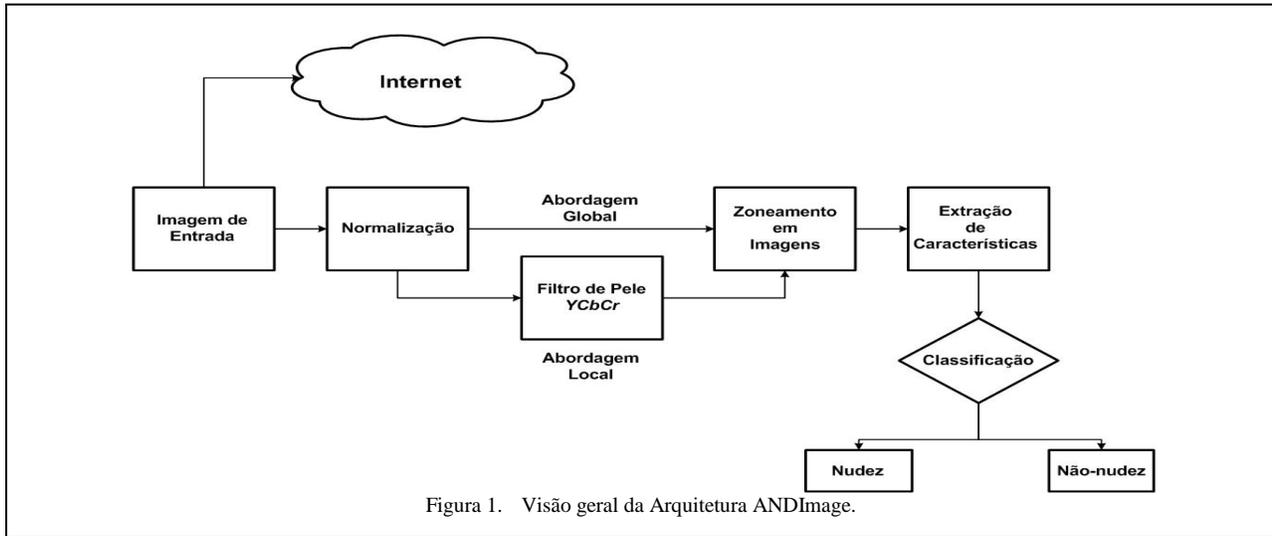
Este trabalho apresenta uma análise e a seleção de características com o auxílio de uma arquitetura denominada ANDImage (*Architecture for Nude Detection in Image*). ANDImage utiliza um módulo de detecção de pele e um módulo de zoneamento de imagens, que divide a imagem em regiões para análise e tratamentos independentes, adotando a hipótese de que em imagens de nudez há uma maior predominância de região de pele no centro da imagem. O módulo de zoneamento também permite a comparação entre características obtidas a partir da detecção de pele, propriedades locais, e características obtidas sem detecção de pele, propriedades globais. A detecção de nudez é realizada pela técnica de aprendizagem de máquina, *Support Vector Machines* (SVM) [2].

II. A ARQUITETURA ANDIMAGE

Como mostrado na Figura 1, a arquitetura ANDImage é composta por um componente normalizador, responsável pela padronização e análise das imagens obtidas na Internet. No caso de propriedades locais, um módulo de detecção de pele é utilizado para tratar a luminosidade nas imagens através do espaço de cor *YCbCr*, segmentando a imagem em busca de áreas de pele. Em seguida, tanto para a extração de características locais como globais, tem-se um módulo de zoneamento em imagens, que divide a imagem em regiões para análise e tratamento independentes, adotando a hipótese de que em imagens de nudez há uma predominância de região de pele no centro da imagem. Por fim, um extrator de característica é aplicado por meio de descritores de cor, textura e forma. As características são, então, usadas pelo componente classificador. Este último classifica a imagem em nudez ou neutra (não-nudez).

Os principais componentes da arquitetura ANDImage são descritos em mais detalhes nas próximas seções.

¹ Dissertação de Mestrado



A. Componente Normalizador

Este componente corresponde a uma camada que torna o sistema independente do formato gráfico a ser tratado, repassando ao módulo seguinte uma imagem totalmente padronizada, em uma mesma dimensão e formato. O processo de normalização das imagens consiste em gerar um novo conjunto de amostras para aplicar a um determinado contexto a ser explorado.

B. Filtro de Pele

O segundo módulo concentra-se na segmentação das imagens em regiões de pele e de não-pele. Como as imagens armazenadas em páginas *Web* podem representar cores de pele de pessoas de várias etnias e diferentes condições de luminosidade, torna-se necessário o emprego de técnicas robustas a essas propriedades para que a detecção de pele ocorra com sucesso. Segundo Lee *et al.* [11], a pele possui a característica de absorver a luminosidade devido à melanina (substância que envolve e protege o cabelo e a pele humana). Logo, é importante o uso de um espaço de cor que isole e trate corretamente a luminosidade em imagens. Existem diversos espaços de cores, sendo que cada um possui particularidades e aplicações específicas. Neste trabalho, o espaço *YCbCr* é usado.

A escolha do espaço de cor *YCbCr* deve-se à propriedade que esse espaço possui de tratar a luminosidade em imagens. Além disso, como a pele humana contém uma gama restrita de valores de *pixels* no espaço de cor, conforme Kelly *et al.* [9], o uso de *YCbCr* proporciona as melhores taxas de detecção de pele, além de reduzir o custo computacional. Maiores detalhes sobre a implementação do filtro de pele são apresentados na Seção III.

C. Zoneamento em Imagens

Neste trabalho, o zoneamento em imagens foi definido como um processo recursivo que divide a imagem toda em k sub-regiões (zonas). Seja I a imagem, $NZ(I)$ o número total de zonas de I , Z uma certa zona de I , $FE(Z)$ o processo de extração de característica de Z , $FV(Z)$ o vetor de

característica de Z e CP o processo de classificação, o algoritmo de zoneamento é definido da seguinte forma:

Algoritmo 1: Definição do Zoneamento em Imagens

```

NZ(I) = k;
Para toda imagem (I) faça;
  Dividir I em NZ;
  Para toda zona (Z) faça;
    FE(Z);
  FE(I) = FE(I) + FE(Z);
Fim;
Fim;
CP(FE(I));
  
```

O algoritmo de zoneamento é brevemente explicado como segue: inicialmente, a entrada é a imagem toda. Dependendo da dimensão, o algoritmo atribui um determinado número de zonas $NZ(I)$ para que a imagem seja dividida a partir do centro. A partir daí, o algoritmo auxilia no processo de extração de características para cada zona $FE(Z)$ com o objetivo de obter o vetor de características da imagem $FE(I)$, que é usado como parâmetro para o processo de classificação $CP(FE(I))$. Vale ressaltar que no trabalho de Kalva *et al.* [8] um algoritmo de zoneamento foi utilizado no processo de busca e classificação de imagens diversas, com propriedades globais, ou seja, a extração de evidências na imagem não requer segmentação. Entretanto, esta técnica ainda não havia sido empregada ao domínio específico de detecção de nudez. Adicionalmente, além da utilização de propriedades globais, também foi utilizada segmentação para filtragem de regiões de pele para descrição de imagens de nudez.

D. Extração de Características

Esta etapa consiste em gerar um vetor de características a partir dos descritores de cor, textura e forma, para posterior processo de seleção de características na classificação de imagens de nudez. Através da análise de alguns trabalhos e de um grande número de imagens, este

trabalho realiza a seleção de características de cor, forma e textura, através de uma comparação e combinação de abordagens que utilizam propriedades globais e propriedades locais.

1) Extração de Características de cor

As características globais de cor utilizadas neste trabalho são baseadas no GCH (*Global Color Histogram*), onde a partir dos dados coletados é possível extrair também informações referentes ao momento do histograma, como média e desvio padrão. Schetinni *et al.* [14] e Sevmili *et al.* [16] são exemplos de autores que utilizam essas evidências para auxílio no processo de detecção de nudez. As características de cor utilizadas são:

Média: Calculada pelo somatório dos valores de níveis de cinza, nc , de todos os n ($n = nlin \times ncol$) *pixels* da imagem divididos pelo número total de *pixels*. É denotada na seguinte fórmula:

$$\mu_i = \frac{\sum_{k=1}^n nc_{ki}}{n} \quad (1)$$

Desvio Padrão: É a raiz quadrada da variância e indica a homogeneidade, ou heterogeneidade, de uma imagem digital, sendo denotada pela fórmula:

$$std = \sqrt{\frac{\sum_{k=1}^n (nc_{ki})^2}{n-1}} \quad (2)$$

2) Extração de Características de Textura

Neste trabalho, as características de textura são extraídas a partir de uma matriz de co-ocorrência (GLCM – do inglês *Gray-Level Co-occurrence Matrix*) proposta por Haralick *et al.* [5]. Cao *et al.* [3] e Zhu *et al.* [20] são exemplos de autores que utilizam a matriz de co-ocorrência para calcular a textura das imagens, através de características como contraste, energia, correlação e homogeneidade, para descrever a imagem que contém nudez. Na GLCM, $P(i, j)$ é uma probabilidade de ocorrência de pares de *pixels* da imagem, sendo i o nível de cinza do *pixel* de interesse da matriz e j o nível de cinza do *pixel* vizinho ao nível de interesse. As quatro métricas obtidas estão listadas abaixo:

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 constante, o contraste é 0 (zero).

$$Con = \sum_{i,j} (i-j)^2 P(i, j) \quad (3)$$

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

$$Corr = \frac{\sum_{i,j} (i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j} \quad (4)$$

Energia. Conhecida também como Segundo Momento Angular, calcula a uniformidade da textura na matriz de co-ocorrência de tons de cinza, ou seja, avalia as repetições de pares de *pixels* em tons de cinza de uma imagem. A energia possui valor 1 para uma imagem constante, onde somente *pixels* similares estão presentes na imagem, ou 0 para heterogênea, quando há grande disparidade entre os *pixels*.

$$Enrg = \sum_{i,j} P^2(i, j) \quad (5)$$

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.

$$Hmg = \frac{\sum_{i,j} P(i, j)}{1 + (i - j)} \quad (6)$$

3) Extração de Características de Formas

Neste trabalho é utilizado o descritor *Edge Histogram Descriptor*, proposto por Won *et al.* [19]. Schetinni *et al.* [14], Jiao *et al.* [6] e Sevmili *et al.* [16] aplicaram essas evidências no processo de detecção de nudez. A extração de características ocorre em três fases: (1) conversão da imagem de entrada para níveis de cinza; (2) detecção de bordas através da aplicação de operadores de Sobel; e (3) aplicação de algoritmos de detecção de linhas horizontais e verticais, linhas inclinadas e pontos isolados, para computar as características na imagem.

4) Extração de Características de Textura

O processo de extração de características locais é realizado a partir da segmentação da imagem obtida através do filtro de pele. Verifica-se que a maioria dos trabalhos da literatura utiliza características baseadas em filtro de pele, como: quantidade de *pixels* de pele conectados e porcentagem de *pixels* de pele na imagem. A descrição das características é dada abaixo:

Quantidade de pixels de pele conectados. Fornece informações referentes ao número de *pixels* de pele conectados N_s . Dado $P(L)$, o número de *pixels* rotulados como pele, essa medida pode ser calculada como:

$$N_s = \sum P(L) \quad (7)$$

Porcentagem de pele. Indica a proporção de segmentos de pele na imagem P_s . Considerando N_s como o número de *pixels* de pele, e N_t o número de *pixels* total da imagem, essa métrica é obtida como:

$$P_s = \frac{N_s}{N_t} \quad (8)$$

Vale ressaltar que a extração de características geométricas da imagem só é necessária quando a imagem não é dividida em zonas. Como o algoritmo de zoneamento geralmente divide a região de interesse, torna-se difícil computar informações de borda, área e perímetro. Logo, informações geométricas não são usadas neste trabalho.

E. Classificação

A última etapa da arquitetura ANDImage corresponde ao processo de classificação das imagens que tem como finalidade, a partir da leitura do vetor de características, distinguir as imagens que pertencem à classe nudez das imagens que pertencem à classe não-nudez. É importante destacar que o sucesso nas etapas anteriores da arquitetura é fundamental para que a etapa de classificação apresente elevada taxa de acerto. Neste trabalho, SVM é utilizado. Essa técnica foi escolhida por apresentar elevadas taxas de acerto em problemas de detecção de pele e de nudez [9].

III. EXPERIMENTOS E ANÁLISE DOS RESULTADOS

Todos os experimentos foram realizados em uma estação de trabalho Core i3, 2,4 MHz, com 4GB de memória e um disco SATA com 320 GB de espaço de armazenamento. Os algoritmos para normalização, filtro de pele e extração de características foram executados em Matlab. O ambiente Weka² foi usado na etapa de classificação.

A. Base de Dados

A base de dados empregada nos experimentos é composta por 5.360 imagens, sendo 2.250 imagens de nudez e 3.110 de não-nudez. Vale ressaltar que a base de dados foi construída pelos autores. Para a análise de desempenho do classificador, a base original foi dividida em bases de treino e teste. A base de treino foi composta por 2.680 imagens, sendo 1.340 imagens de nudez e 1.340 imagens de não-nudez, totalizando 50% do conjunto inicial de imagens. A base de teste foi constituída pelas 2.680 imagens restantes.

B. Desenvolvimento da Arquitetura ANDImage

Com a finalidade de desenvolver um sistema de detecção de nudez em imagens, foi projetada e desenvolvida a arquitetura descrita na Seção II, que é composta pelos módulos como normalização; filtro de pele; zoneamento; extração de características e classificação. Nesta seção serão apresentadas informações sobre o processo de normalização, aplicação do filtro de pele e zoneamento.

Normalização

Em geral, as imagens contidas na base continham um tamanho médio de 800x600 *pixels*. Foram utilizadas diversas configurações para normalizar as imagens (32x32, 64x64, 128x128, 256x256). Por fim, as imagens foram padronizadas em um valor aproximado de 256 colunas por 256 linhas.

Filtro de Pele

Foi utilizado um conjunto de amostras de zonas de pele, com dimensões de 30x30 *pixels* cada, extraídas de diversos pontos de faces de pessoas de variadas etnias (caucasianos, africanos, europeus, asiáticos, indianos, entre outros) e sob diferentes condições de luminosidade. As imagens foram convertidas de RGB para *YCbCr*. Em seguida, através da análise de histograma, os valores médios de cromaticidade (componentes *Cb* e *Cr*) das imagens foram obtidos. Por fim,

foi observado que os valores de *pixels* referentes à pele variam em *Cb* de 77 a 127 e em *Cr*, de 133 a 173.

A Figura 2 mostra um exemplo de imagens e seus correspondentes resultados após a aplicação do filtro de pele. Os resultados do filtro de pele foram publicados em Santos *et al.* [13]. É importante observar nas imagens da Figura 2, que o cabelo é confundido com região de pele, fato ocasionado pela concentração de melanina que absorve a luminosidade, substância mais abundante em pessoas de raça negra [7].

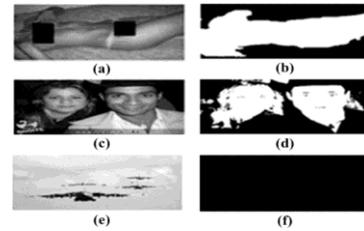


Figura 2. Imagens que demonstram o resultado do filtro de pele, onde (a) representa uma imagem original de nudez; (b) o resultado do filtro de pele na imagem de nudez; (c) imagem de pessoas com roupa; (d) o resultado do filtro de pele para pessoas com roupa; (e) imagem original que não contém pele e; (f) o resultado do filtro na imagem que não contém pele.

Zoneamento em Imagens

Neste trabalho, a definição do número de zonas está relacionada diretamente com o processo de normalização de imagens. Como as imagens foram padronizadas em um tamanho aproximado de 256 colunas por 256 linhas, o algoritmo de zoneamento atribuiu três zonas para a imagem. Vale ressaltar que, diversos testes foram realizados para a definição do número exato de zonas para cada configuração de imagem, pois quando as imagens são reduzidas a um tamanho de 64x64, há uma considerável perda de dados e a aplicação do algoritmo de zoneamento é desnecessária. Os resultados do zoneamento e análise de características foram publicados em Santos *et al.* [12]

A Figura 3 exibe exemplos de zoneamento obtidos através da divisão da imagem em três regiões retangulares concêntricas e proporcionais à sua dimensão.

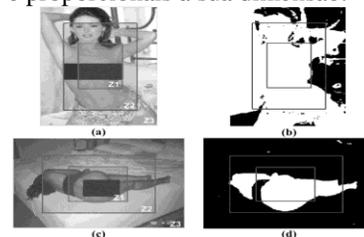


Figura 3. Imagens que demonstram o resultado da aplicação do zoneamento, onde (a) e (b) representam uma imagem de nudez com orientação na horizontal e o resultado do zoneamento, (c) e (d) imagem de nudez com orientação na vertical e o resultado do zoneamento.

C. Ajustes de Parâmetros de SVM

Foram realizados ajustes de parâmetros de SVM durante a fase de treinamento. Para este fim, foi utilizada a estratégia de validação cruzada. O *Kernel* RBF apresentou resultados superiores ao *Kernel* polinomial. Além do tipo de

² <http://www.cs.waikato.ac.nz/~ml/weka>

Kernel, SVM tem o parâmetro de penalização C que precisa ser ajustado, enquanto que o valor γ precisa ser definido para o *Kernel* RBF. Em nossos experimentos, esses parâmetros foram definidos como $C = 100$ e $\gamma = 0,7$.

D. Resultados

Nesta seção são discutidos os resultados obtidos na etapa de classificação, com ênfase nas comparações das abordagens globais e locais para detecção de nudez. Além disso, são apresentados os resultados da seleção de subconjuntos de características obtidos através de uma análise qualitativa das características, conhecida na literatura como *Wrapper* [10]. Nesses experimentos, cada característica é analisada isoladamente para que seja determinado o impacto individual no desempenho do classificador. Em seguida, diversas combinações foram testadas a fim de determinar o melhor compromisso entre o conjunto de características e a precisão do classificador. Como consequência, tem-se a redução da dimensão do espaço de entrada e o aumento da precisão.

Por fim, também foram comparadas as características através da aplicação do algoritmo de zoneamento para analisar o impacto das características em cada zona da imagem. Desta forma, busca-se confirmar a hipótese de que em imagens de nudez há uma predominância de *pixels* de pele no centro da imagem.

1) Análise das Características Globais

Na abordagem global, as características foram extraídas sem a necessidade de realização de segmentação das imagens. Foram analisados três grandes grupos de características: cor, forma e textura, tanto de forma isolada, quanto de forma combinada. Utilizando-se o conjunto de todas as características globais, SVM foi capaz de alcançar 91,3% de precisão, tendo um vetor composto por 235 atributos. Já com o conjunto formado apenas com as características mais relevantes (*histograma*, *desvio padrão*, *homogeneidade* e *correlação*), SVM alcançou 91,1% de precisão com um vetor formado por 211 atributos. Foi observado que houve uma economia de 10,3% no espaço de armazenamento devido à redução do vetor de características, sem perda significativa de taxa de acerto.

2) Análise das Características Locais

Na abordagem local são utilizadas apenas duas características (*quantidade de pixels de pele* e *porcentagem de pixels de pele na imagem*). Isoladamente, as características fornecem informações suficientes para SVM alcançar elevada taxa de desempenho em detecção de nudez. Isso mostra a eficiência de modelos de detecção de nudez baseados em regiões, onde o tempo para pré-processar a imagem é compensado pelo tamanho reduzido do vetor de características. Entretanto, para melhorar a precisão desta abordagem, é realizada a combinação das características locais com evidências globais e a aplicação do zoneamento para analisar a distribuição das características em regiões específicas da imagem e confirmar a hipótese de que há uma maior concentração de *pixels* de pele no centro da imagem.

3) Combinação das Abordagens Global e Local através do Zoneamento em Imagens

Esta abordagem visa combinar características globais e locais e, ao mesmo tempo, analisar a relevância de cada característica em uma determinada zona da imagem, de maneira a selecionar as características mais relevantes e reduzir a dimensão do espaço de características.

Através do zoneamento em imagens e análise de características foi possível observar que:

- As características possuem grande variabilidade, dependendo da região de aplicação;
- As características de textura se configuram como um excelente conjunto de dados para detecção de nudez, pois atuam como o grande diferencial na confusão de *pixels* de pele;
- As características de formas só fornecem dados suficientes para aprendizado do classificador caso as informações sejam extraídas de regiões específicas da imagem, ou seja, caso a imagem seja particionada. Outro fator observado neste conjunto de características é o fato de somente possuir relevância na região central da imagem, ou seja, a região que geralmente compreende os objetos de interesse;
- Nenhum grupo de características foi suficientemente relevante na *zona 3*, pois nesta região as características são comuns a todos os tipos de imagens, tornando as informações insuficientes para o aprendizado do classificador;
- A *quantidade de pixels de pele* na *zona 1*, ou seja, centro da imagem, configurou-se como uma importante característica para detecção de imagens de nudez, confirmando a hipótese adotada no objetivo do trabalho, conforme Figura 4.

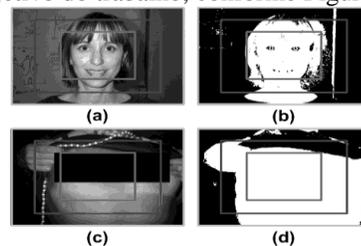


Figura 4. Imagens que demonstram o resultado da aplicação do zoneamento, em que (a) representa o zoneamento em imagens de face, (b) o resultado do zoneamento em imagens de face após a aplicação do filtro de pele, (c) o zoneamento em imagem de nudez, (d) o resultado do zoneamento em imagens de nudez após o filtro de pele.

4) Análise de Tempo de Execução

Também vale destacar a necessidade de análise da eficiência das abordagens investigadas, ou seja, o tempo necessário para que cada imagem seja analisada em cada abordagem. Essa informação é importante para ser verificada a aplicabilidade da arquitetura ANDImage em sistemas *online*. Segundo Zhu *et al.* [20] o tempo de execução ideal para que uma abordagem seja aplicável em sistemas *online* deve ser inferior a 0,3 segundos por imagem (s/i). A Tabela I exhibe uma comparação da eficiência da

arquitetura ANDImage através da análise de características com e sem a utilização do zoneamento para descrição de imagens de nudez.

TABELA I. ANÁLISE DA EFICIÊNCIA DA ARQUITETURA.

	Sem Zoneamento		Com Zoneamento	
	Todas as caract.	Melhor subconjunto de caract.	Todas as caract.	Melhor subconjunto de caract.
<i>Normalização</i>	0,07s/i	0,07s/i	0,07s/i	0,07s/i
<i>Extração de características</i>	0,12s/i	0,05s/i	0,15s/i	0,06s/i
<i>Classificação</i>	0,11s/i	0,09s/i	0,19s/i	0,15s/i
<i>Tempo Médio do Processo</i>	0,30s/i	0,21s/i	0,41s/i	0,28s/i
<i>Precisão / Falso Negativo</i>	91,9% / 11,1%	91,7% / 11%	97,3% / 4%	98,8% / 1,6%
<i>Quantidade de Atributos</i>	237	211	711	424

Como visto na tabela acima, é possível observar que com o processo de seleção de características, sem o zoneamento em imagens, o tempo de execução reduz em aproximadamente 9 (nove) milissegundos, enquanto a precisão fica praticamente inalterada. Quando este mesmo processo é realizado através do zoneamento em imagens, o tempo de execução reduz em até 13 milissegundos. Como o tempo gasto para processar cada imagem foi abaixo de 30 milissegundos (cerca de 28 milissegundos por imagem), pode-se afirmar que nossa arquitetura se configura como um problema para aplicações *online*.

Além disso, a seleção de características possibilitou a redução da dimensão do espaço de características e, conseqüentemente, a eliminação de ruídos no classificador, ocasionando aumento na precisão. Outros fatores que podem ser observados estão relacionados ao aumento da precisão em aproximadamente 7% e redução percentual de falsos negativos em 9%, obtidos com o zoneamento.

IV. CONCLUSÕES

Neste trabalho foi realizada uma análise e seleção de características para detecção de nudez com o auxílio de uma arquitetura que permite o uso de propriedades globais, locais e zoneamento em imagens. SVM foi utilizado para classificar as amostras em nudez ou neutra (não-nudez).

As tentativas de combinação das características globais e locais através do algoritmo de zoneamento produziram elevadas taxas de desempenho, pois foi possível aumentar a precisão em aproximadamente 7%, em relação a não utilização do zoneamento em imagens. A partir da análise de características, foi possível selecionar algumas características das zonas 1 e 2, resultando na redução de 46% do vetor de características e aumento da precisão devido à eliminação de ruídos no classificador. Além disso, o tempo gasto para processar cada imagem pode ser considerado aplicável em sistemas *online*, sendo abaixo de 30 milissegundos.

Dessa forma, a combinação de propriedades globais e locais, juntamente com a aplicação do zoneamento em

imagens se faz necessária para reconhecimento de imagens de nudez, configurando-se como um método aplicável a diversos domínios de reconhecimento de objetos.

REFERÊNCIAS

- [1] Arentz, W. A. & Olstad, B. (2004) "Classifying Offensive Sites Based on Image Content". *Computer Vision and Image Understanding* 94. pp. 295-310.
- [2] Burges, C. J. C. (1998) "A tutorial on Support Vector Machines for Pattern Recognition". *Data Mining and Knowledge Discovery*, Vol. 2, pp. 121-167.
- [3] Cao, L. L.; Li, X. L.; Yu, N. H. & Liu, Z. K. (2002) "Naked People Retrieval Based on Adaboost Learning", *ICMLC 2002*, pp 1133 - 1138.
- [4] Fleck, M.; Forsyth, D.A. & Bregler, C. (1996) "Finding naked people", *Proc. 4th European Conf. On Computer Vision*, vol. 2, pp. 593-602.
- [5] Haralick, R. M.; Shanmugam, K. & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, n. 6.
- [6] Jiao, F.; Gao, W.; Duan, L. & Cui, G. (2001) "Detecting Adult Image using Multiple Features", *Proc. International Conference Info-tech and Info-net (ICII 2001)*, pp.378-383.
- [7] Jones, M. J. & Rehg, J. M. (2002) "Statistical Color Models with Application to Skin Detection". *Computer Vision*, Vol. 46, pp. 81-86.
- [8] Kalva, P. R.; Enembreck, F. & Koerich, A. L. (2008) "WEB Image Classification using Combination of Classifiers", *IEEE Latin America Transactions*, vol. 6, pp. 661-671.
- [9] Kelly, W.; Donnellan, A.; & Molloy, D. (2007) "Screening for Objectionable Images: A Review of Skin Detection Techniques". Em *International Conference Machine Vision and Image Processing ICMVIPPA '07*, pp. 310-319.
- [10] Kohavi, R. & John, G. H. (1997) "Wrappers for Feature Subset Selection", *Artificial Intelligence*, Vol. 97 (1-2), pp. 273-324.
- [11] Lee, J. S.; Kuo, Y. M.; Chung, P.C. & Chen, E. L. (2007) "Naked Image Detection Based on Adaptive and Extensible Skin Colour Model", *Pattern Recognition*, Vol. 40, pp. 2261-2270.
- [12] Santos, C. A. M.; Santos, E. M.; Souto, E. J. P. (2012) "Nudity Detection Based on Image Zoning" In: *ISSPA 2012*, Montreal, Canadá.
- [13] Santos, C. A. M.; Pinto, K. M. B.; Santos, E. M.; Souto, E. J. P. (2011) "Análise de Características para Detecção de Pele em Imagens. In: *CBIC'11*, Fortaleza - Ceará.
- [14] Schetini, R.; Brambilla, C.; Cusano, C. & Ciocca, G. (2003) "On the Detection of Pornographic Digital Images", *VCIP'03*, pp. 2105-2113.
- [15] Symantec. 2011. Symantec Internet Security Threat Report – Trends for 2011, 20 p.
- [16] Sevmili, H.; Esen, E.; Ates, T. K.; Ozan, E. C.; Tekin, M.; Logoglu, B.; Sevinç, A. M.; Saracoglu, A.; Yazici, A. & Alatan, A. A. (2010) "Adult Image Content Classification Using Global Features and Skin Region Detection", *ISCIS'10*, Springer, Vol. 62, pp. 253-258.
- [17] Wang, X. Hu, C. & Yao 2009. An Adult Image Recognizing Algorithm on Naked Body Detection. *IEEE International Colloquium on Computing Communication, Control and Management*, pp. 197-200.
- [18] Wang, J.; Li, J.; Wiederhold & Firschein, G. (1998) "System for Screening Objectionable Images" *Comp. Communications*. pp. 20-30.
- [19] Won, C.-S.; Park, D.-K. & Park, S.-J. (2002) "Efficient Use of MPEG-7 Edge Histogram Descriptor" *ETRI Journal*, vol. 24 (1), pp.23-30.
- [20] Zhu, H.; Zhou, S.; Wang, J. & Yin, Z. (2007) "An Algorithm of Pornographic Image Detection". In *Fourth International Conference on Image and Graphics (ICIG 07)*. pp. 801-804.