

ANÁLISE DA INFLUÊNCIA DA ILUMINAÇÃO NA CLASSIFICAÇÃO DE FACES EM IMAGENS DIGITAIS

Dielly de Oliveira **VIANA**¹; Eanes Torres **PEREIRA**².

¹Aluno do curso de Computação;

²Professor do curso de Computação;

Departamento de Computação, Universidade Estadual da Paraíba - UEPB, Campus I, Campina Grande-PB. E-mail: diellyviana@msn.com, eannes@gmail.com.

RESUMO

Este artigo apresenta um estudo da influência da iluminação na classificação de faces humanas em imagens digitais. Foram usadas as imagens da base *The Yale Face Database B* que é composta de 5850 imagens de faces adquiridas sobre condições de iluminação variadas sistematicamente. As seguintes características foram extraídas das imagens: valores dos *pixels*, histogramas dos valores dos *pixels*, componentes principais extraídos por meio de PCA e LBP. Essas características foram utilizadas para treinar e testar os seguintes classificadores: máquinas de vetores de suporte e redes neurais artificiais. Além disso, a extração das características foi realizada global e localmente e métodos básicos de combinação de classificadores foram aplicados. Os resultados experimentais comprovaram a superioridade da utilização de redes neurais com características LBP extraídas localmente para a tarefa de classificação de imagens de faces com variações de condições de iluminação.

PALAVRAS CHAVE: Extração de Características, Variações de Iluminação, Classificação de Faces, Características Globais e Locais, Métodos de Aprendizagem de Máquina.

1 INTRODUÇÃO

A área da visão computacional é repleta de aplicações e peculiaridades. Analisando esses aspectos, é possível verificar determinadas relevâncias no uso de algumas aplicações, tendo como base o processamento de imagem digital e reconhecimento facial. Em Cavalcanti et al. (2010) e Cavalcanti et al. (2011) é proposto um método de automação de ajuste da imagem na região mais importante, ou seja, o algoritmo detecta a face do indivíduo, o software aplica o *zoom* na região detectada como mais importante e posteriormente o algoritmo elimina o restante da imagem sem que a região sinalizada seja degradada. Os problemas encontrados foram os mesmos estudados neste trabalho: o fator da iluminação e o posicionamento do rosto interferem drasticamente na detecção, influenciando o resultado final.

Veloso et al. (2007) propõem uma abordagem utilizando detecção de faces, a partir da detecção são realizadas marcações manuais dos pontos na face com a finalidade de mapear características relevantes de acordo com cada expressão facial. O estudo procura satisfazer além da detecção da face, classificar qual expressão facial o indivíduo está fazendo, tais com: alegria, tristeza, surpresa, medo, raiva e nojo.

O foco principal apresentado aqui será a análise de imagens com face em condições de iluminação e sombreamento acentuadas. Não é pretensão deste trabalho propor uma nova técnica para detecção de face, mas sim estudar a melhor combinação entre os vários métodos de extração de características que serão detalhadas na seção 3 e os diferentes classificadores

existentes na área de detecção de objeto que serão detalhados na seção 4, a fim de tratar o problema da iluminação e sombreamento.

Há várias bases de imagens disponíveis para pesquisa em detecção de face, a base adotada nesse trabalho foi a *The Yale Face Database B¹* que possui em sua característica faces com vários níveis de iluminação e conseqüentemente sombreamento de ângulos diferentes, o que torna seu uso bastante viável nesse trabalho.

2 TRABALHOS RELACIONADOS

Nesta seção é apresentada uma discussão sobre os principais trabalhos na área de detecção de faces humanas em imagens digitais que estão relacionados com a pesquisa cujos resultados são descritos neste artigo.

Uma abordagem proposta por Pereira et al. (2011), mostram que as combinações de classificadores treinados obtiveram resultados mais elevados do que os classificadores treinados e testados isoladamente. As características foram extraídas de modo global e local assim como foi feito neste trabalho. No modo de extração local, varias analises foram realizadas para verificar quais regiões seriam candidatas à extração de características, entre elas: tamanhos e formas das regiões e as relações entre elas, teste com validação cruzada, ajuste do custo e gama no *kernel-SVM*. Foram utilizadas imagens de face com poses frontais (incluindo semiperfis) e perfis, as taxas de acerto foram de 91,7% e 99,59%, respectivamente.

Várias abordagens para detecção de faces em imagens digitais foram propostas. Dentre as mais promissoras, podem ser destacadas:

- Múltiplas redes neurais usando como entrada os valores das intensidades dos *pixels* das imagens, proposta por Rowley et al. (1998).
- Treinamento Adaboost (FREUND & SCHAPIRE, 1997) usando características do tipo harr, proposta por Viola e Jones (2001) idem (2004).
- Treinamento Adaboost utilizando características LBP (Local Binary Patterns) (OJALA et al., 1996), proposta por Rodriguez (2006).
- Classificador Bayesiano treinado com características extraídas usando uma variação do descritor SIFT (*Scale Invariant Feature Transform*, (LOWE, 2004)), proposta por Toews e Arbel (2009).

Analisando as abordagens mencionadas, observa-se que nenhuma delas oferece robustez a todos os principais problemas de variação em imagens de faces: orientação, iluminação e oclusão. Rowley et al. (1998) tratam o problema de detecção de faces em múltiplos pontos de vista e orientações treinando redes neurais especialistas em faixas de variação de ângulos. Um problema associado a este método é a impossibilidade de processamento em tempo real devido a grande quantidade de testes, correspondente à quantidade de redes neurais testadas, pelos quais uma imagem deve passar.

O método proposto por Viola e Jones (2001) possui bastante robustez a variações de orientação das faces no plano e fora do plano. Para obter tal robustez, é proposto no método o treinamento de vários classificadores cada um usando imagens de faces obtidas a partir de um ponto de vista diferente. Por exemplo, se o objetivo é ter um detector de faces robusto a variações de

¹ <http://vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html>

orientação no plano entre -15 e +15 graus que detecte imagens frontais e de perfil, então serão treinados pelo menos dois classificadores um para faces frontais e outro para faces de perfil. Em seguida, os classificadores são combinados para gerar o classificador final que será usado para detectar faces. Este método utiliza uma abordagem para representação de imagens que possibilita a extração rápida de características das imagens, o método Imagem Integral (CROW, 1984).

Um dos métodos mais simples e rápidos para extração de características de textura de imagens é o LBP (Local Binary Patterns) (OJALA et al., 1996). Rodriguez (2006) propôs uma abordagem semelhante a que foi proposta por Viola e Jones (2001). Porém, Rodriguez (2006) usou características LBP. Um dos diferenciais do trabalho de Rodriguez (2006) é o protocolo de avaliação de detectores de faces orientado a objetivo. Rodriguez (2006) afirma que um detector de faces deve ser avaliado segundo o objetivo a que se destinam as faces detectadas pelo mesmo. Ou seja, se as faces detectadas se destinam a reconhecimento, então o detector deve ser avaliado acoplado a um reconhecedor de faces à sua saída.

Por ser um método genérico, que realiza detecção, reconhecimento e distinção de gênero sexual, o método proposto por Toews e Arbel (2009) obteve resultados moderados em detecção de faces. Este método trata variações de orientação da face e oclusão. Porém, os testes com oclusão são realizados com imagens que possuem oclusão sintética (círculos pretos pintados em diferentes localizações das faces). A oclusão sintética proposta no trabalho de Toews e Arbel (2009), não reflete as situações reais e pode levar a resultados tendenciosos.

Nenhum dos trabalhos mencionados nesta seção trata explicitamente dos problemas de oclusão e iluminação, nem apresenta uma avaliação específica do comportamento dos métodos propostos em relação a algum dos problemas. Para amenizar a influência de sombras fortes ou muita intensidade luminosa o que é comum na literatura é a realização de equalização de histogramas das imagens como etapa de pré-processamento. Além disso, alguns autores propuseram abordagens para extração de características que possuem robustez a variações de iluminação.

Segundo Marcel et al. (2007), o LBP é invariante a transformações monotônicas de tons de cinza o que torna essa representação menos sensível a mudanças de iluminação. Além disso, foram propostas extensões do método LBP que o tornam ainda mais robusto a variações de iluminação. Por exemplo, o ILBP (Improved Local Binary Pattern) que toma como valor de comparação a média dos *pixels* de uma vizinhança e não o valor do pixel central como no LBP original (JIN et al., 2004).

Novas técnicas surgiram de acordo com a junção de algumas já existentes, é o caso do extrator proposto por Pereira et al. (2010) que aborda uma técnica incremental utilizando o LBP (Local Binary Patterns) proposto por Ojala et al. (1996). Esse método é chamada de INTLBP (*Improved Local Binary Pattern*) que utiliza-se da técnica da abordagem de imagem integral para representar histogramas de LBP. Em Pereira et al. (2010) afirmam que essa técnica aumenta a velocidade de processamento na detecção de face e aumenta a taxa de acerto comparado à abordagem do LBP Invariante a Rotação (OJALA et al., 2002).

3 METODOLOGIA

Nesta seção serão expostos os procedimentos usados para a realização desta pesquisa. Será apresentada uma descrição geral da organização dos dados na Seção 3.1 e na Seção 3.2 os métodos de extração de características serão comentados.

3.1 DESCRIÇÕES GERAIS DA ORGANIZAÇÃO DOS DADOS

A base de imagens disponível publicamente para download que melhor se adapta aos objetivos desta pesquisa é a *The Yale Face Database B* (Ver Figura 1), pois retrata uma vasta gama de situações diferentes de sombreamento/iluminação.

Figura 1 - Exemplo de faces contidas na base de dados.



Fonte: <http://vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html>

Um conjunto de imagens da base adotada contendo 4390 faces frontais foi redimensionado para a resolução de 21 x 21 pixels a fim de melhorar a precisão do classificador. Após o redimensionamento, as imagens foram separadas em grupos diferentes. Cada grupo continha um conjunto de imagens para treinamento e teste. Os conjuntos foram organizados de forma que nenhuma imagem estaria repetida em outro. Um procedimento similar foi realizado com as imagens de não face. Um total de 133200 imagens de não faces foram extraídas a partir da base de imagens disponibilizada por Naotoshi Seo em sua página sobre treinamento de cascatas de classificadores².

3.2 MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS

As características extraídas das imagens para realizar os treinamentos e testes foram: valores das intensidades dos pixels das imagens em tons de cinza, histogramas calculados utilizando os valores das intensidades dos pixels, componentes obtidos com Análise de Componentes Principais (*Principal Componente Analysis – PCA*), padrões binários locais obtidos por meio da utilização do operador LBP (*Local Binary Patterns*) (OJALA et al., 1996).

3.2.1 VALORES DOS PIXELS

Este método trabalha com o valor de todos os pixels da imagem a ser processada. Se uma imagem possui dimensões de 21x21 a quantidade de pixels dessa imagem será de um total de 441 pixels que conseqüentemente será o total de características obtidas para o processamento do classificador. Nota-se que quanto maior a dimensão da imagem (x,y) maior será a


² <http://tutorial-haartraining.googlecode.com/svn/trunk/data/negatives/>

quantidade de informação a ser tratada, o que implica numa maior carga de dados, aumentando o tempo de processamento.

3.2.2 HISTOGRAMA DE CINZA

Um histograma é uma representação da frequência de ocorrências de valores. Para uma imagem, um histograma pode ser usado para contar a ocorrência dos valores das intensidades dos pixels. Cada número que corresponde à quantidade de ocorrências pode ser chamado de bin. Um histograma também pode ser usado para verificar a ocorrência de valores em faixas pré-determinadas. Por exemplo, para calcular histogramas para uma imagem em tons de cinza que utiliza 8 bits para representar os 256 níveis de intensidade diferentes podemos usar diversas quantidades de bins. Se usarmos, por exemplo, 8 bins, cada bin conterá a quantidade de vezes que os valores em faixas 32 níveis ocorreram. No caso de 8 bins, as faixas seriam: 0 a 31, 32 a 63, 64 a 95, etc. A Figura 2 (a) exibe um exemplo de uma imagem com 4x5 pixels e a distribuição da intensidade dos pixels.

Figura 2 - Representação da distribuição do histograma de cinza.



Após o cálculo da intensidade de cada pixel é feita a quantização desses valores por faixas de níveis, como mostrado na figura 2 (b). É visto que o bin zero possui sete pixels com intensidade zero, por outro lado, a maior intensidade (de cor mais clara), possui apenas uma representação no bin 3.

3.2.3 PCA (*Principal Component Analysis*)

A Análise de Componentes Principais (PCA) consiste em utilizar operações lineares de forma a reduzir significativamente a quantidade representacional dos dados extraídos de alguma fonte. Sendo assim, a quantidade de características utilizada poderá ser diminuída de acordo com a escolha do usuário. As principais etapas para a realização do PCA, segundo Vasconcelos (n.d.) são: cálculo das médias dos dados obtidos e posteriormente é subtraída de cada valor dos dados a média calculada. Feitas essas operações, será calculada a matriz de covariância, utilizando essas subtrações. O próximo passo é calcular os autovetores de comprimento 1 (não nulos) e autovalores. Por último a matriz é organizada de forma que os valores mais significativos são dispostos de forma decrescente, ficando assim uma lista dos mais importantes até os menos significativos. Com isso é possível obter um número reduzido de padrões de característica da imagem, melhorando o desempenho no processamento e classificação da face.

3.2.4 LBP (*Local Binary Patterns*)

O LBP é um algoritmo de extração de características bastante robusto na detecção de face, tendo em vista sua facilidade de manipulação e integração com outras técnicas. O LBP é bastante utilizado, tendo em vista sua invariância à rotação e sua capacidade de invariância à iluminação. O LBP original proposto por Ojala et al. (1996) é baseado em valores dos vizinhos do pixel central. Uma grade com 3x3 é utilizada com um valor pré-definido do raio de ação dos vizinhos que varre a imagem a fim de atribuir valores de zeros e uns a cada valor do pixel. Se o valor do pixel do vizinho for maior que o valor do pixel central é atribuído o valor 1 àquela posição do pixel, caso contrário será atribuído zero. A disposição dos zeros e uns garante nesse método a contagem de transições entre eles, fazendo dessa transição um padrão que é adotado pelo classificador. Como há diversas variações para extração de características LBP recomenda-se a leitura de Pereira et al. (2010), Ojala et al. (1996), Ojala et al. (2002), Rodriguez (2006), Marcel et al. (2007), e Viola e Jones (2001) para aprofundamento no tema.

4 CLASSIFICADORES UTILIZADOS

As características extraídas foram utilizadas para treinar dois tipos de classificadores: máquinas de vetores de suporte e redes neurais artificiais. Foram utilizadas as seguintes bibliotecas como implementações dos classificadores:

- LibSvm: A library for support vector machines (Uma biblioteca para máquinas de vetores de suporte)³;
- LibFann: Fast artificial neural network library (Biblioteca de redes neurais artificiais rápida)⁴.

4.1 SVM (*Support Vector Machines*)

As máquinas de vetores de suporte, são uma excelente ferramenta para o reconhecimento de padrões, por outro lado são ferramentas de aprendizado supervisionado. A SVM trabalha com modelos de entrada e com isso é capaz de tomar decisões em dados desconhecidos, gerando uma saída (resposta). Além disso, utiliza-se da análise estatística detalhada dos dados, seu algoritmo foi baseado no modelo desenvolvido por Vapnik (1995), para uma classificação confiável e bem sucedida, o que torna seu uso bastante aceitável no meio acadêmico, científico e de pesquisa. Segundo Lorena e Carvalho (2003) o ponto forte da SVM é sua capacidade de generalização dos dados e sua forma de separação das classes dos dados treinados e testados. Para mais detalhamento sobre SVM recomenda-se a leitura de Tahim (2010) e Lorena e Carvalho (2003).

4.2 RNA (*Redes Neurais Artificiais*)

As Redes Neurais Artificiais (RNA) são fundamentadas em modelos computacionais baseados em ligações, ou seja, existe uma estrutura com capacidade de realizar alguma operação à qual estão ligadas entre si a fim de

³ <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>

⁴ <http://leenissen.dk/fann/wp/>

compartilharem informação/dados com algum objetivo. A RNA tem a característica de aprendizado através do fornecimento de dados, ou seja, assim como as SVMs as RNAs também tem em sua forma o aprendizado supervisionado como apontam Portugal e Fernandes (1996). Os benefícios do uso das redes neurais artificiais (RNA) se dá pelo fato da sua capacidade de fazer diversas operações em tempo reduzido, além disso, a RNA tem a capacidade de modelar qualquer função determinada, isso se dá pelo fato da quantidade de informação que a RNA pode obter em sua estrutura. Para estudos mais aprofundados em redes neurais artificiais recomenda-se a leitura de Haykin (1998).

5 RESULTADOS

Nesta seção serão apresentados, em forma de tabela os resultados obtidos nos experimentos feitos de acordo com o tema proposto. Todos os testes continham 4.390 imagens de face e 120.000 imagens de não face.

5.1 RESULTADOS USANDO CARACTERÍSTICAS GLOBAIS

Aqui serão apresentados os resultados globais dos experimentos. Diz-se que a característica foi extraída globalmente quando é usada a imagem em sua totalidade.

Na Tabela 5.1 é possível verificar que a taxa de acerto de imagens de não face, em geral é superior a taxa de acerto de imagens de face por parte dos classificadores. Podemos analisar que a taxa de acerto de face usando os valores dos pixels combinados com SVM é muito inferior quando combinados com a RNA. Analisando pelo lado computacional, usando valores dos pixels temos 441 características extraídas de uma imagem de 21x21, ao contrário do PCA que foram utilizadas 80 características de cada imagem, o que diminui a demora do processamento de cada imagem por parte do classificador. De modo global é possível concluir que ao utilizar o classificador SVM, o PCA obteve a melhor taxa de acerto em ambas as classes (face e não face) utilizando em média 20% da característica de cada imagem.

Tabela 5.1 - Resultados em porcentagem usando características globais

Taxa de Acerto em %	SVM		RNA	
	Face	Não Face	Face	Não Face
Valores Dos Pixels	71%	99%	87%	98%
PCA	92%	98%	89%	97%

5.2 RESULTADOS USANDO CARACTERÍSTICAS LOCAIS

A seguir serão apresentados os resultados dos testes realizados usando os parâmetros locais, ou seja, a imagem foi dividida em regiões, onde de cada região eram extraídas as características independentes das outras regiões que eram concatenadas de acordo com o método utilizado.

Na Tabela 5.2 é possível perceber algumas peculiaridades que surgiram em conjunto com o método local de extração. Ao analisarmos as taxas de acerto obtidas no PCA, verificamos que seu uso não é bem representado pelo classificador ao usá-lo localmente, embora sua taxa de acerto de não face

tenha permanecido alta, a taxa de acerto de face foi muito abaixo dos valores obtidos na Tabela 5.1. A taxa de acerto para não face em todos os métodos de extração de características locais, permaneceram com uma elevada taxa de acerto por parte do classificador.

Outra característica observada é que a quantidade de bins usados no método do histograma de cinza interfere diretamente na taxa de acerto de cada tipo de classificador. Em experimentos usando histograma de cinza com regiões de 7x7 a melhor taxa de acerto foi obtida usando como classificador uma RNA e a taxa de acerto para face foi de 74% usando 15 bins. Ao diminuir o tamanho das regiões (e aumentando sua quantidade), as taxas de acerto do histograma de cinza usando 3x3 sofreram uma melhora de aproximadamente 25% na taxa de acerto de face em ambos os classificadores, ao contrario da característica apresentada com o PCA que ao dividir as regiões da imagem a taxa de acerto diminuiu com relação a extração global.

O mesmo aconteceu com o LBP, onde em imagens com regiões de 7x7 pixels, a taxa de acerto de face usando SVM foi de 66%. Essa mesma característica foi testada usando uma RNA com histogramas de 8 bins e a taxa de acerto para face atingiu 99%. Porém, essas taxas de acertos foram melhoradas ao dividir o LBP em regiões de 3x3, elevando as taxas de acerto de face para 96% usando SVM, uma melhora de 30%. Utilização uma RNA, os valores são ainda melhores, a taxa de acerto para face chega a 99% e 93% para não face.

Tabela 5.2 - Resultados em porcentagem usando características locais

Taxa de Acerto em %	SVM		RNA	
	Face	Não Face	Face	Não Face
Histograma de Cinza 7x7	62%	98%	74%	96%
Histograma de Cinza 3x3	87%	98%	98%	94%
PCA 10x10	70%	99%	81%	94%
LBP 7x7	66%	84%	99%	86%
LBP 3x3	96%	89%	99%	93%

6 CONCLUSÕES

Para o estudo realizado, é possível verificar que os tipos de extrações de características se comportam de maneira diferente dependendo do tipo de classificador associado, assim como, as taxas de acertos são influenciadas de acordo com a forma de extração (Global ou Local). É possível fazer alguns ajustes no classificador SVM em busca de melhores resultados e utilizar combinações de classificadores treinados com características diferentes para obter melhores resultados, conforme proposto por Pereira et al. (2011).

Como o objetivo foi a análise da influência da iluminação com extrações locais e globais com a variação do método de extração da característica e o tipo de classificador, podemos concluir que a combinação LBP (com regiões de 3x3 e um total de 49 regiões) com o RNA como classificador tiveram melhor resultado utilizando-se de extração local. Confirmando assim, seu poder de

insensibilidade a diferentes luminosidades como afirmam Marcel et al. (2007). Para o método global, a melhor combinação ficou com PCA e SVM.

7 TRABALHOS FUTUROS

Como trabalho futuro, pretende-se propor um método para detecção de faces que utilize os resultados obtidos neste estudo para alcançar uma precisão elevada.

REFERÊNCIAS

CAVALCANTI, CLAUDIO. S. V. C.; GOMES, HERMAN. M.; QUEIROZ, JOSÉ. E. R. Combining Multiple Image Features to Guide Automatic Portrait Cropping for Rendering Different Aspect Ratios. **6th International Conference on Signal-Image Technology & Internet-Based Systems**, Kuala Lumpur. v. 1. p. 66-73, 2010.

CAVALCANTI, CLAUDIO. S. V. C.; GOMES, HERMAN. M.; QUEIROZ, JOSÉ. E. R. An Extended Evaluation of Methods for Portrait Cropping. **Journal of Multimedia Processing and Technologies**, v. 1, p. 245-259, 2011.

CROW, F. Summed-area tables for texture mapping. **Proceedings of the 11th annual conference on Computer Graphics and interactive techniques**. p. 207-212, 1984.

FREUND, Y.; SCHAPIRE R. E. A decision-theoretic generalization of on-line learning and an application to boosting. **Journal of Computer and System Sciences**, 55, 1997.

GEORGHIADES, A.S.; BELHUMEUR, P.N.; KRIEGMAN, D.J. From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose. **IEEE Trans. Pattern Anal. Intelligence**. v. 3, n. 6, p. 643-660, Mach, 2001

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**, 2nd Ed. Prentice Hall, 1998.

JIN, H.; LIU, Q.; LU, H.; TONG, X. Face detection using improved LBP under bayesian framework. **International Conference on Image and Graphics**. Hong Kong, China, p. 306-309, 2004.

LORENA, A. C.; CARVALHO, A. C. P. L. **Introdução as Máquinas de Vetores Suporte**. São Carlos - SP, Abril 2003.

LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints, **International Journal of Computer Vision**, v.60, n. 2, p. 91-110, 2004.

MARCEL, S.; RODRIGUEZ, Y.; HEUSCH, G. On the recent use of Local Binary Patterns for Face Authentication. **International Journal of Image and Video Processing**. Special Issue on Facial Image Processing, 2007.

OJALA, T.; PIETIKÄINEN, M.; HARDWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern Recognition**, v. 29, n. 1, p. 51-59, 1996.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE**

Transactions on Pattern Analysis and Machine Intelligence, vol. 24, p. 971–987, 2002.

PEREIRA, EANES T.; GOMES, HERMAN. M.; CARVALHO, JOÃO. M. Integral Local Binary Patterns: a Novel Approach Suitable for Texture-Based Object Detection Tasks. **23rd SIBGRAPI Conference on Graphics, Patterns and Images**, Gramado - RS, 2010.

PEREIRA, EANES T.; GOMES, HERMAN. M.; MOURA, EDUARDO. S.; CARVALHO, JOÃO; ZHANG, T. Investigation of Local and Global Features for Face Detection. **IEEE Symposium on Computational Intelligence for Multimedia, Signal and Vision Processing**. CIMSIVP, Paris, 2011.

PORTUGAL, MARCELO S.; FERNANDES, LUIZ G. L. **Redes Neurais Artificiais e Previsão de Séries Econômicas**: Uma Introdução, Nova Econômica, Vol. 6, n.1, 1996.

RODRIGUEZ, Y. Face Detection and Verification using Local Binary Patterns. **Phd thesis**, Ecole Polytechnique Federale de Lausanne, 2006.

ROWLEY, H.; BALUJA, S.; KANADE, T. Neural network based face detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 20, p. 23-38, 1998.

TAHIM, ANDRÉ P. N. **MÁQUINAS DE VETORES DE SUPORTE (SVM)**, Março, 2010. Disponível em: <http://www.andretahim.com/publicacoes.html>. Acesso em: Out. 2012.

TOWES, M.; ARBEL, T. Detection, localization, and sex classification of faces from arbitrary viewpoints and under occlusion. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 31, n. 9, p. 1567-1581, 2009.

VAPNIK, V. N. **The nature of Statistical learning theory**. Springer-Verlag, New York, 1995.

VASCONCELOS, SIMONE. (n.d.). **Análise de Componentes Principais**. Disponível em: www.ic.uff.br/~aconci/PCA-ACP.pdf. Acessado em: Out. 2012.

VELOSO, LUCIANA R.; CARVALHO, JOÃO M.; CAVALVANTI, CLAUDIO S. V. C.; MOURA, EDUARDO S.; COUTINHO, FELIPE L.; GOMES, HERMAN M. Neural Network Classification of Photogenic Facial Expressions Based on Fiducial Points and Gabor Features. **PSIVT**, p. 166-179, 2007.

VIOLA, P.; JONES, M. Robust real-time object detection. **Second International Workshop on Statistical and Computational Theories of Vision – Modeling, Learning, Computing, and Sampling**, 2001.

VIOLA, P.; JONES, M. Robust real-time face detection. **International Journal of Computer Vision**. v. 57, n. 2, p. 137-154, 2004.