

Eye detection Approaches based on AdaBoost and SVM algorithms

Flávio das Chagas Prodossimo
Universidade Tecnológica Federal
do Paraná
Curitiba, Paraná
Email: frovas@gmail.com

Chidambaram Chidambaram
Universidade Estadual
de Santa Catarina
São Bento do Sul, Santa Catarina
Email: chidambr@gmail.com

Heitor Silvério Lopes
Universidade Tecnológica Federal
do Paraná
Curitiba, Paraná
Email: heitorslopes@gmail.com

Resumo—Face Recognition is an area of Computer Vision which is widely studied today. Face Recognition depends on many steps for its implementation, one of this steps is the detection of eyes. This can be used to extract features or as an initial step for the normalization of face images. In this work two approaches are proposed to detect the eyes. First approach is based on the Viola and Jones and the second approach is based on LBP (Local Binary Pattern), VNS (Variable Neighborhood Search) and SVM (Support Vector Machines). To evaluate both approaches, computational experiments are done. According to the detection performance, the Viola and Jones overcomes the SVM. However, both approaches are effective in detecting eye regions.

I. INTRODUÇÃO

O reconhecimento facial (RF) está sendo aplicado em diversas áreas, como exemplo, no combate à falsificação de passaportes, identificação de criminosos e acesso a áreas restritas. Com os avanços e o fácil acesso a tecnologias, a captura de imagens por câmeras de segurança se tornou comum e vem aumentando a quantidade de imagens e vídeos. Além disso, nos últimos anos, vem crescendo o desenvolvimento de métodos e algoritmos nesta área. Neste contexto, a demanda por sistemas automáticos de RF cresceu nos últimos anos. A comunidade científica tem feito várias pesquisas com o objetivo de identificar pessoas usando somente a imagem da face. Para tanto, empregam-se técnicas e métodos científicos de diversas áreas, tais como Visão Computacional, Reconhecimento de Padrões, Inteligência Computacional e Métodos de Busca [20].

De modo geral, o reconhecimento de pessoas através de faces ainda constitui uma tarefa desafiadora, pois as imagens que contém faces possuem alta variabilidade em tamanho, forma, cor e textura. Portanto, nas últimas décadas, inúmeras técnicas vêm sendo desenvolvidas para identificar faces. Desta forma, cresce a demanda por métodos eficientes e robustos para a localização de faces humanas em imagens ou vídeos digitais.

O RF abrange diversas etapas da Visão Computacional. Estas etapas vão desde a captura de imagens para treinamento do sistema até a fase de reconhecimento. As etapas incluem detecção da face, detecção dos olhos, normalização da face, extração de características e a comparação de base de imagens com a imagem de busca [15], [20]. Dentro deste cenário, uma etapa importante é a Detecção de Regiões de Interesse (*ROI - Region of Interest*). Estas regiões podem ser os olhos, a face ou outras regiões que forneçam algum tipo de informação útil

para o reconhecimento, no caso deste trabalho, a região dos olhos ou os olhos em si. Com isso é possível realizar a etapa de normalização, que é responsável por padronizar a posição e o tamanho de elementos da face em relação à imagem.

O principal objetivo deste trabalho é detectar o centro dos olhos para normalizar as imagens faciais. Consequentemente, a detecção de regiões dos olhos entre vários componentes faciais se torna prioritária pois os olhos são os elementos faciais mais relevantes para o reconhecimento. O posicionamento dos olhos é utilizado em outras etapas, na extração de características, por exemplo [20]. Portanto, o foco principal deste trabalho é comparar duas metodologias de detecção de ROIs. A primeira baseada no algoritmo de Viola e Jones [18], o algoritmo clássico mais utilizado na literatura, principalmente para detecção de faces em imagens com várias pessoas. Na segunda abordagem utiliza-se um algoritmo de extração de textura LBP (*Local Binary Pattern*) [12] em conjunto com a Máquina de Vetores de Suporte, SVM (*Support Vector Machine*) [17] e o algoritmo de busca, VNS (*Variable Neighborhood Search*) que é uma Meta-heurística [10].

Diversos algoritmos podem ser utilizados para auxiliar a Detecção de ROIs. A seguir são apresentados alguns filtros de imagens, além de algoritmos de reconhecimento de padrões de otimização de busca, que visam facilitar as metodologias de detecção.

As próximas sub-seções dão um embasamento teórico sobre o trabalho desenvolvido e também apresentam-se alguns trabalhos relacionados (Seção I-F). Na Seção II está a explicação sobre o desenvolvimento deste trabalho. Alguns experimentos e os resultados são apresentados na Seção III. E, por fim, na Seção IV, são expostas as considerações finais.

A. Local Binary Pattern

O filtro de texturas, LBP foi proposto por [12]. A ideia principal deste filtro foi baseado em um modelo de análise de texturas, onde a região de textura era representada por 8 elementos (uma região de vizinhança de 3x3 pixels). Neste modelo, cada um dos elementos pode receber 3 valores (0, 1 e 2), totalizando em 6561 (3^8) texturas diferentes. Já na versão atual, cada elemento pode ser dividido em 2 valores, com isso reduz o número de possíveis texturas para 256. A Figura 1 representa o processo de aplicação do filtro LBP.

O exemplo da Figura 1 mostra que a imagem original (a) é analisada a partir do pixel central. Todos os pixels vizinhos




Figura 1. Procedimento do LBP [12].

são analisados e recebem valor 1 caso seja maior ou igual ao pixel central e 0 caso contrário (b). Os valores binários são multiplicados, elemento a elemento, pela matriz de valores na potência de 2 (c), resultando na matriz (d). Por fim o pixel central recebe a soma dos resultados da matriz (d), resultando na imagem (e).

O LBP é um filtro geralmente utilizado para classificação, por isso é necessário um algoritmo de Reconhecimento de Padrões para treinar e classificar as imagens processadas pelo filtro. O algoritmo mais utilizado na literatura em conjunto com o LBP é o SVM, explicado na Seção I-C.

B. Algoritmo Viola e Jones

Esta abordagem de aprendizado de máquina para detecção de objetos foi proposto por Viola e Jones [18]. Suas três principais contribuições marcantes são: a representação de imagens através de imagens integrais para extrair características de modo rápido em várias escalas, onde as imagens foram filtradas com o filtro *Haar-like Features*; a construção de um classificador selecionando um conjunto pequeno de características através do Adaboost; e por último, a construção de um classificador complexo numa estrutura cascata que drasticamente aumenta a velocidade do detector focando apenas nas regiões promissoras. Neste trabalho, as características *Haar-like* foram utilizadas na detecção por conterem informações mais relevantes do que uma pequena quantidade de pixels individualmente.

A Figura 2 mostra o processo de execução do Viola e Jones, onde em cada quadro as características são extraídas para fazer o reconhecimento com o Adaboost. As características são calculadas da seguinte forma: soma-se os níveis de cinza da região destacada em preto no retângulo e subtrai da soma dos níveis de cinza da região branca do retângulo.



Figura 2. Exemplo de execução do algoritmo Viola e Jones.

C. Máquinas de Vetores de Suporte - SVM

A classificação através de algoritmos de reconhecimento de padrões, por exemplo, SVM, é feita através de treinamento, que consiste na apresentação de diversos dados para o algoritmo que, por sua vez, estabelecerá um padrão. As etapas básicas de um algoritmo de reconhecimento de padrões podem ser vistos na Figura 3. A primeira etapa consiste na obtenção de vários dados de exemplo que serão utilizados pelo algoritmo no treinamento ou teste. Estes dados passam pelo Pré-Processamento, e então, extrai-se as características relevantes para a classificação. Na etapa seguinte ocorre o treinamento ou teste usando o algoritmo de classificação.




Figura 3. Etapas de um algoritmo de Reconhecimento de Padrões.

As SVMs são caracterizadas pelo aprendizado estatístico que consiste em definir uma série de pontos em um espaço multidimensional e encontrar um hiperplano que separe esses pontos em classes diferentes. Isto é, o algoritmo estabelece relações matemáticas para criação de um classificador de acordo com o conjunto de dados que lhe foi apresentado para treinamento. Os dados treinados pelo SVM clássico podem ser divididos em somente duas classes distintas.

D. Variable Neighborhood Search (VNS)

Os algoritmos de busca são responsáveis por encontrar a melhor solução possível dentro de um espaço de busca através de tentativas. Um exemplo deste tipo algoritmo é chamado VNS, proposto por [10]. Esta tem como princípio básico pesquisar no espaço de busca utilizando o princípio da vizinhança. O VNS prossegue a busca através de método descida, para um local mínimo e, então, explora uma série de vizinhanças pré-determinadas. A partir destes locais mínimos, tenta escapar dos vales com a perturbação. Ao contrário de outras Meta-heurísticas, o VNS não segue nenhuma trajetória, porém, explora cada vez mais as vizinhanças distantes em relação à solução atual. Atua numa vizinhança e muda para uma nova somente se encontrar uma melhoria em relação à atual vizinhança. Além do mais, numa determinada vizinhança, a rotina da busca local é repetidamente aplicada para encontrar um ótimo local.

A estrutura de vizinhança pode ser definida como um conjunto finito pré-selecionado de estruturas de vizinhanças, representado por N_k , onde $k = 1, \dots, k_{max}$ é o conjunto de soluções do k-ésimo vizinho de x , por $N_k(x)$. O pseudocódigo básico do VNS é apresentado abaixo [5]:

Inicialização:

- Selecione um conjunto de estruturas de vizinhança N_k ;
- Encontre uma solução inicial x ;
- Defina uma condição de parada;
- Repita até atender o critério de parada:
 - i. $k = 1$;
 - ii. Repita até $k \leftarrow k_{max}$:

- Perturbação de variáveis;
 - (Gera um ponto x' aleatoriamente do k-ésimo vizinho de x onde $x' \in N_k(x)$;

- Busca local usando como a solução inicial x' selecionando x'' como ótimo local;
- Mudança de vizinhança:
Se x'' for melhor que o inicial (x),
então mude para a nova vizinhança ($x \leftarrow x''$) e
continua busca $N_1(k \leftarrow 1)$,
caso contrário, $k \leftarrow k + 1$;

O critério de parada pode ser determinado por um número máximo de iterações ou número máximo de iterações entre duas melhorias [5]. A vantagem do VNS é que este permite encontrar soluções ótimas ou próximas à ótima em um tempo moderado. O VNS é simples, rápido e exige apenas um parâmetro que é o número de estruturas de vizinhança. Além do mais, esta meta-heurística pode ser facilmente hibridizada [10]. Este algoritmo foi inicialmente focado nas aplicações de otimização combinatorial e também, nos problemas de otimização global.

E. Detecção de Regiões de Interesse

A Detecção de ROIs é importante para o RF, pois a partir destas regiões é que se iniciam outros processos, como a normalização e a extração de características. Estas regiões geralmente incluem a face, a região dos olhos (Figura 4) e o centro do olho (pupila). Para a etapa de normalização de faces, o mais importante é a pupila onde o ponto central de cada um dos olhos deve ser detectado.




Figura 4. Região dos Olhos.

os métodos de detecção de olhos são classificados em ativo e passivo. O método ativo é usado para detectar olhos em sequências de vídeos enquanto o método passivo é mais utilizado em imagens. Este método possui três abordagens: análise de aparência, aprendizagem e modelos [2]. Na primeira abordagem, análise de aparência, são utilizadas características de cor, textura e formas. Agrupamentos de pele são formados em algum espaço de cor, feitos através de análise estatística de pele humana presente nas imagens. As vantagens desta abordagem são a necessidade de poucos recursos computacionais e, também, pelo fato de que os cálculos de características serem invariantes a escala, rotação, cores ou formas. A principal desvantagem é a dificuldade de estabelecer critérios para identificar pele de várias etnias e em imagens com variação de iluminação [2].

Para a abordagem de aprendizagem um classificador é treinado utilizando um conjunto de imagens de exemplos e de contraexemplos. O treinamento pode ser feito utilizando técnicas como: Redes Neurais, SVMs, entre outras. Nesta abordagem, os problemas de rotação, escala e iluminação podem ser anulados pela geração de vários exemplos que representem estas características. A maior desvantagem está na definição de um bom contraexemplo para o treinamento [2].

A detecção por modelos tem como o princípio básico o casamento de uma imagem modelo com regiões da imagem onde há face. Como exemplo, pode-se citar o *Template Matching* (TM). No processo por TM, geralmente, procura por um padrão em uma imagem paisagem (imagem com fundo, cenário, múltiplas faces etc.), ou seja, o melhor casamento entre uma imagem referência ou de busca e cada recorte (janela) da imagem paisagem. Uma imagem modelo ou de referência podem ser a de imagens de olhos recortadas de uma face ou um padrão composto por um círculo e duas curvas, formando um modelo de olho [2]. A principal desvantagem deste método é o alto custo computacional, pelo grande espaço de busca e pela necessidade de modificar o modelo em relação à escala e rotação.

F. Trabalhos Relacionados

Embora o foco do trabalho seja de detectar os olhos, o processo quase sempre se inicia com a detecção de faces. Os métodos existentes podem ser agrupados em três grandes áreas: Métodos baseado em conhecimento, Abordagens baseado em características invariantes e Métodos que utilizam *templates* [19]. Na literatura, é mais comum encontrar trabalhos relacionados às últimas duas áreas. No trabalho de [8], a detecção de olhos foi feita seguindo uma série de etapas que incluem a segmentação da pele, a detecção de bordas, as operações morfológicas, o cálculo de medidas geométricas entre os olhos, e por último, a aplicação de diversos *templates*. A melhor taxa de acerto foi de 91,23% para faces com rotação menor que 20° e o pior caso foi para rotações maiores que 60° onde a taxa de acerto foi de 62,21%.

De modo similar ao trabalho anterior, em [9] também foi utilizada a detecção da região da face através da cor da pele utilizando-se o espaço de cores YCrCb. Neste, a região de interesse dos olhos foram detectados aplicando-se o filtro de Gabor. Neste trabalho, Ke e Huang [9] obtiveram 94% de acerto com imagens frontais e 83% para imagens com rotação. No estudo de [7], utilizou-se imagens em níveis de cinza com baixa resolução. Neste trabalho, primeiramente, utilizando o algoritmo Viola e Jones [18], detectou-se a face, e então, foram detectadas duas regiões, uma para cada olho. Na etapa seguinte, a posição da pupila de cada olho foi localizada através do TM, utilizando a soma das diferenças absolutas. [7] perceberam que, quando a imagem da face é transformada para níveis de cinza, a região central do olho é formada por um círculo preto, e assim quatro *templates* sintetizados foram definidos. Utilizando esses *templates* formados por um círculo preto e uma pequena borda branca, a melhor taxa média de acerto, em torno de 95,5%, foi obtida.

No trabalho de [13] foi utilizada a técnica de TM. As imagens utilizadas nos experimentos não passaram por nenhum pré-processamento. Os *templates* utilizados nos experimentos foram obtidos das próprias imagens faciais. A busca para o *matching* dos *templates* foi otimizada com dois algoritmos de otimização baseada em inteligência de enxames, Colônia de Abelhas, ABC (*Artificial Bee Colony*), utilizado por [1], e Busca Harmônica, HS (*Harmony Search*), utilizado por [16]. Da mesma forma, o ABC também foi utilizado em estudos de detecção de íris por [7].

Para a detecção de sorrisos no trabalho de [3] foi utilizada uma combinação do LBP e SVM, a primeira para extração

de características e a segunda, classificação das imagens. Para o treinamento da SVM foram utilizadas imagens de 59x65 pixels, sendo que existiam 2421 imagens de faces com sorriso e 3360 sem sorriso. Nos melhores casos a taxa de acerto do algoritmo de [3] foi de aproximadamente 90%.

II. DESENVOLVIMENTO

O desenvolvimento deste trabalho é baseado em duas abordagens de detecção de olhos que é essencial para normalização automática de faces. A primeira abordagem é baseada em algoritmo clássico de Viola e Jones e a segunda, é baseada no SVM que classifica as imagens. Porém, na segunda, foi utilizada LBP para extrair as características de textura e VNS, para realizar a busca no espaço de imagem levando em consideração a escala e a rotação. O algoritmo Viola e Jones foi adaptado para detectar outras regiões, não somente a face como o algoritmo original. Portanto, o algoritmo utilizado neste trabalho localiza a região de olhos numa imagem facial.

O procedimento de detecção dos olhos (Figura 5) utilizado foi o mesmo para as duas abordagens, diferindo somente pelo algoritmo de classificação e método de extração de características. No caso do algoritmo Viola e Jones, primeiramente a imagem é apresentada ao sistema que detecta uma região retangular em que estão situados os dois olhos. Em seguida, dentro desta região, o algoritmo busca os dois olhos, retornando ao mesmo tempo, o ponto central de cada um dos olhos. Para extração de características, o Viola e Jones utiliza *Haar-Like Features* e o treinamento é feito usando Adaboost.




Figura 5. Procedimento de Detecção dos Olhos.

Na abordagem baseada em LBP e SVM, inicia-se a busca por uma região ótima na imagem facial que melhor represente uma região de olhos. Então usando os parâmetros gerados pelo VNS, a imagem retangular é recortada da imagem facial (paisagem) e pré-processada usando o filtro de textura LBP. Assim, o vetor de características da imagem é construído. Este vetor servirá como o exemplo de teste para o SVM que classificará a região cortada como uma região de olhos ou não. Assim, o processo de busca por uma região ótima será repetida através de várias iterações pré-determinadas. Para treinamento do algoritmo proposto foram utilizadas 483 imagens de regiões de olhos (Figura 5) e, em seguida, foram utilizadas 966 imagens contendo somente os olhos. Com isso pode-se realizar as duas etapas da detecção de forma separada.

Em seguida, foram realizadas validações do algoritmo utilizando o mesmo número de imagens do treinamento, ainda utilizando o algoritmo SVM. Com o algoritmo validado e funcionando, o SVM foi re-treinado juntando o conjunto de treinamento e o conjunto de validação, resultando em 966 imagens para re-treino dos recortes da região dos olhos e 1932 imagens para recortes dos olhos. O treinamento final foi armazenado em arquivos para serem utilizados nos testes, sem a necessidade de novos treinamentos a cada execução da detecção dos olhos.

III. EXPERIMENTOS E RESULTADOS

Os experimentos foram realizados utilizando a base de imagens faciais apresentada no trabalho de [14]. Com o objetivo de criar um banco de imagens para projetos de pesquisa na área de reconhecimento facial, as imagens frontais foram capturadas de acordo com algumas normas, estabelecidas pelos documentos [6] e [11] e pelo relatório técnico M1/03-0114 [4]. A iluminação do ambiente de captura das imagens foi feita artificialmente, algumas imagens com fonte de iluminação própria e outras com a iluminação da sala, caracterizando dois ambientes. A base de imagens contém 138 classes de indivíduos diferentes. A base foi criada em 2012 com intuito de ser pública, porém, ela ainda está em fase organização e testes. Somente as imagens frontais foram utilizadas e estão agrupadas usando os códigos a seguir: FI1, FI1exp, FI1esc e FI1il são imagens frontais com a fonte de iluminação 1, sem expressão, com expressão, com escala e com sombra lateral, respectivamente; e os códigos FI2 e FI2exp são imagens frontais com a segunda forma de iluminação, sem expressão e com expressão, respectivamente. Exemplos das imagens, nesta mesma ordem, são apresentadas na Figura 6.




Figura 6. Exemplos das imagens utilizadas nos experimentos.

Com o objetivo de avaliar as duas abordagens, realizaram-se dois experimentos utilizando esta base de imagens. Os resultados são apresentados nas Tabelas I e II. Na primeira abordagem as soluções não variam quando o algoritmo é executado mais de uma vez. Já no outro algoritmo as soluções mudam, pelo fato de se utilizar um algoritmo baseado em meta-heurística de busca onde existe uma certa aleatoriedade para iniciar as variáveis. Por isso, na Tabela II os valores mostrados são o resultado da média entre várias execuções.

Com os resultados apresentados na Tabela I, é possível notar que o algoritmo de Viola e Jones supera o SVM tanto no número de acertos quanto no tempo de processamento para encontrar os olhos. O melhor número de acertos foi para as imagens frontais com a iluminação 2, em compensação foi o que mais demorou, em média, para encontrar os olhos na face. No geral, o melhor caso pode ser observado com os testes das

imagens com escala e iluminação 1, onde o tempo médio foi o menor dentre os testes, errando somente em duas faces.

Tabela I. RESULTADOS DA DETECÇÃO DE OLHOS COM O ALGORITMO VIOLA E JONES.

Pose	Tempo Médio (s)	Tempo Total (s)	Acertos
FI1	2,2	305	131
FI1exp	2,7	373	126
FI1esc	2,1	300	136
FI1II	2,7	385	134
FI2	2,9	404	137
FI2exp	2,2	304	135

A Tabela II mostra os resultados obtidos da média de 20 rodadas de execução do algoritmo proposto usando SVM e VNS, já o desvio padrão das execuções é mostrado no gráfico da Figura 7. Na Tabela II observa-se que este algoritmo é mais lento, porém, na maioria dos casos é eficiente para encontrar os olhos na face. Sendo que, na média, o maior número de acertos foi 131 com tempo médio por imagem de aproximadamente 27 segundos. Porém, nas imagens com a escala, a número de acertos foi de 108, bem abaixo do que encontrado por o algoritmo Viola e Jones que obteve 136 acertos.

Tabela II. RESULTADOS DA DETECÇÃO DE OLHOS COM O ALGORITMO LBP COM SVM.

Pose	Tempo Médio (s)	Tempo Total (s)	Acertos
FI1	26,5	3664	130
FI1exp	26,9	3725	125
FI1esc	26,9	3721	108
FI1II	22,7	3135	130
FI2	27,1	3753	131
FI2exp	27,5	3795	124

O gráfico da Figura 7 mostra os resultados de todos os testes, onde cada coluna representa uma categoria de imagens. Sendo que os teste do algoritmo Viola e Jones sempre apresenta o mesmo número de acertos, independente de número de execuções. Isso está representado por uma linha vermelha no gráfico. Como o VNS é o algoritmo de otimização, portanto, na segunda abordagem com SVM, os resultados são mostrados usando o desvio padrão (linha azul vertical) e a média (centro da linha azul) dos testes.




Figura 7. Comparação de número de acertos entre Viola e Jones e SVM

Conforme mostrado na Figura 8, a abordagem baseada em SVM e LBP atinge uma taxa de acertos aproximadamente menor que 26% a do Viola and Jones na categoria de imagens com escala e a iluminação própria (FI1esc). Ao mesmo tempo, na categoria de expressão facial com a iluminação ambiente

(FI2exp), a diferença de taxa de acertos entre as duas foi de 9%.




Figura 8. Diferença de número de acertos entre os algoritmos

Baseado na análise dos resultados, percebe-se que a região do nariz foi a que mostrou maior erro de detecção dentre todas as regiões. Isto pode ter acontecido pelo fato de existir uma semelhança de textura entre as regiões de olhos e de nariz caracterizada por dois círculos escuros dentro de uma região clara. Algumas imagens de regiões detectadas erroneamente podem ser observadas na Figura 9.




Figura 9. Regiões detectadas erroneamente.

IV. CONSIDERAÇÕES FINAIS

De acordo com os experimentos realizados, verifica-se que, de modo geral, as duas abordagens propostas são eficientes para detectar olhos em imagens de faces humanas. Porém, considerando o tempo de execução, o algoritmo de Viola e Jones se torna o mais rápido e robusto. Embora a abordagem baseada em SVM e LBP tenha alcançado resultados inferiores à Viola e Jones, a proposta poderá servir de referência para análises futuras e outros trabalhos relacionados. A continuação deste trabalho consta em normalizar as imagens da base mencionada [14] de forma automática, utilizando os pontos centrais dos olhos encontrados pelo algoritmo. Assim, construir uma base de imagens faciais normalizadas que é essencial no processo de reconhecimento de faces.

REFERÊNCIAS

- [1] C. Chidambaram and H. S. Lopes. An improved artificial bee colony algorithm for object recognition problem in complex digital images using template matching. *International Journal of Natural Computing Research*, 1(2):54–70, 2010.
- [2] B. de Brito Leite. Detecção de olhos em imagens com faces humanas. Master's thesis, Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2008.

- [3] D. Freire, M. C. Santana, and O. Déniz-Suárez. Smile detection using local binary patterns and support vector machines. *Proceedings of the Fourth International Conference on Computer Vision Theory and Applications (VISAPP 2009)*, 1:5 – 8, 2009.
- [4] P. Griffin. Face recognition format for data interchange. Technical report, Identix Corporate Research Center, Minnetonka - MN, 2003. Relatório Técnico.
- [5] P. Hansen and N. Mladenovic. Variable neighborhood search: Principles and applications. *European Journal of Operational Research*, 130:449–467, 2001.
- [6] R. Islam. *Police Standard for Still Digital Image Capture and Data Interchange of Facial/Mugshot and Scar, Mark and Tattoo Images*. National Policing Improvement Agency, United Kingdom, 2.0 edition, Maio 2007. Manual.
- [7] J. C. S. J. Jacques, J. L. Moreira, A. Braun, and S. R. Musse. A template-matching based method to perform iris detection in real-time using synthetic templates. *Proceedings of IEEE International Symposium on Multimedia*, pages 142–147, 2009.
- [8] W. Jian and Z. Honglian. Eye detection based on multi-angle template matching. *Proceedings of International Conference on Image Analysis and Signal Processing*, pages 241 – 244, 2009.
- [9] L. Ke and Y. Huang. Eye location based on dual-orientation gabor filters and templates. *Proceedings of International Congress on Image and Signal Processing*, page 4, 2009.
- [10] N. Mladenovic and P. Hansen. Variable neighborhood search. *Computers and Operations Research*, 24:1097 – 1100, 1997.
- [11] NIST. *Face Recognition Format for Data Interchange - Best Practices*. United States, 2007. Manual de Boas Práticas.
- [12] T. Ojala, M. Pietikäinen, and D. Harwood. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29:51 – 59, 1996.
- [13] F. C. Prodossimo, C. Chidambaram, and H. S. Lopes. Otimização da detecção de olhos em imagens faciais utilizando os algoritmos colônia de abelhas artificiais e harmony search. *Anais do X Congresso Brasileiro de Inteligência Computacional*, 2011.
- [14] F. C. Prodossimo, C. Chidambaram, and H. S. Lopes. Proposta de uma metodologia para a construção de um banco de imagens faciais normalizadas. *Anais do VIII Workshop de Visão Computacional*, 2012.
- [15] D. Reisfeld and Y. Yeshurun. Preprocessing of face images: Detection of features and pose normalization. *Computer Vision and Image Understanding*, 71:413–430, 1998.
- [16] M. H. Scalabrin, R. S. Parpinelli, and H. S. Lopes. Paralelização do algoritmo harmony search utilizando unidade de processamento gráfico. *Mecânica Computacional*, 29:7109–7121, 2010.
- [17] V. N. Vapnik. *The nature of Statistical learning theory*. Springer-Verlag, New York, 1995.
- [18] P. Viola and M. Jones. Rapid object detection using a boosted cascade of simple features. *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1:511 – 518, 2001.
- [19] M.-H. Yang, D. J. Kriegman, and N. Ahuja. Detecting faces in images: A survey. *IEEE Transactions on Pattern Recognition and Machine Intelligence*, 21(1):34–58, 2002.
- [20] W. Zhao, R. Chellappa, P. J. Phillips, and A. Rosenfeld. Face recognition: A literature survey. *ACM Computing Surveys*, 35:399–458, 2003.