

OTIMIZAÇÃO DA DETECÇÃO DE OLHOS EM IMAGENS FACIAIS UTILIZANDO OS ALGORITMOS COLÔNIA DE ABELHAS ARTIFICIAIS E *HARMONY SEARCH*

Flávio das Chagas Prodossimo

Universidade Tecnológica Federal do Paraná
frovas@gmail.com

Chidambaram Chidambaram

Universidade do Estado de Santa Catarina
chidambr@gmail.com

Heitor Silvério Lopes

Universidade Tecnológica Federal do Paraná
heiterslopes@gmail.com

Resumo – A tarefa do reconhecimento facial geralmente inicia por detecção de olhos, que é considerada como a fase mais importante. De modo geral, a detecção de olhos é necessária para detecção e normalização de faces e ainda, para extração de características. O encontro dos olhos na imagem facial pode ser feita através de uso de *templates*. Porém, a imagem facial poderá ter várias partes similares. Portanto, o uso da técnica *Template Matching* e de algoritmos de otimização pode tornar mais eficiente a localização de olhos. Neste trabalho a busca é otimizada usando o algoritmo de *Harmony* (HS) e o algoritmo Artificial de Colônia de Abelhas (ABC). Considerou-se nos experimentos os fatores como escala e rotação da imagem, além da localização espacial (eixos x e y). Os resultados são comparados para avaliar o desempenho dos algoritmos discutidos neste trabalho. Com o trabalho foi possível notar tanto o *Harmony Search* quanto o algoritmo de Colônia de Abelhas detectaram os olhos nas faces, algumas vezes com os olhos centralizados na imagem recorte.

Palavras-chave – Detecção de olhos, Correlação, *Harmony Search*, Colônia Artificial de Abelhas, Otimização.

Abstract – The task of face recognition begins with eye detection that is considered the most important phase. In general, the eye detection is needed for face detection and normalization and feature extraction. The matching of the eyes can be done through templates. However, the use of the technique *Template Matching* and optimization algorithms can make more efficient the eye location. In this work the search is optimized using the *Harmony Search* (HS) algorithm and the Artificial Bee Colony algorithm. It was considered in the experiments scale and rotation factors, in addition to spatial location (x and y axes). The results are compared to evaluate the performance of the algorithms discussed in this paper. With the work we became aware that the *Harmony Search* Algorithm and the Artificial Bee Colony detected eyes in the faces, sometimes with the eyes centered in the cutout image.

Keywords – Eye detection, Matching, *Harmony Search*, Artificial Bee Colony, Optimization.

1. INTRODUÇÃO

Com a evolução da Tecnologia da Informação, tem se tornando comum o reconhecimento de pessoas através de imagens obtidas através de câmeras de monitoramento ou imagens estáticas. Por questões de segurança, tem aumentado a demanda por sistemas automáticos para reconhecimento de faces, tanto na área pública quanto privada. Há muitos estudos e pesquisas que vêm sendo desenvolvidos pela comunidade científica com o objetivo de identificar pessoas usando somente a imagem da face. Para tanto, emprega-se técnicas e métodos científicos de diversas áreas, tais como Visão Computacional, Reconhecimento de Padrões e Inteligência Computacional.

De modo geral, o reconhecimento de pessoas através de faces ainda se constitui uma tarefa desafiadora, pois as imagens que contém faces possuem alta variabilidade em tamanho, forma, cor e textura. Ainda mais, há necessidade de identificação de faces invariantes à posição, orientação ou variações de iluminação. Nas últimas décadas, inúmeras técnicas têm sido desenvolvidas para identificar faces numa base de imagens, por exemplo, usando as imagens de olhos como *templates* [1]. Desta forma, tem aumentado a demanda por métodos eficientes e robustos para a localização de faces humanas em imagens digitais, exigindo grande esforço computacional, técnicas inovadoras e algoritmos eficientes.

O reconhecimento facial requer diversas etapas [2]. Estas etapas incluem a detecção e normalização da face, extração de características e comparação com as imagens armazenadas em uma base. Dentre tais etapas, a mais importante é a detecção da

face propriamente dita. Esta fase é etapa essencial para as etapas seguintes. Neste contexto, o elemento facial mais importante para o reconhecimento são os olhos. A detecção dos olhos facilita o processo de normalização, que é necessária para padronizar as imagens.

Um processo bastante utilizado para encontrar padrões em imagens é o *Template Matching* (TM). O TM consiste em comparar a imagem de entrada e as imagens *templates* (padrões) da base através da correlação [3]. Neste trabalho a comparação é feita entre os *templates* de olhos predefinidos e a imagem de um olho extraída da imagem da face. Portanto, esta técnica leva à comparação exaustiva entre duas imagens [4], o que é computacionalmente custoso [3]. Para agilizar o processo de detecção de olhos através do TM e, ao mesmo tempo, reduzir o número de comparações, pode-se utilizar os algoritmos de otimização, neste caso, os algoritmos de Computação Evolucionária [5]. Dentre estes algoritmos podem ser citados: os Algoritmos Genéticos (AG), algoritmos baseados em Enxames de Partículas (*PSO-Particle Swarm Optimization*) e Colônia de Abelhas (*ABC-Artificial Bee Colony*), algoritmos baseados na música (*HS-Harmony Search*) [6], entre outros.

Neste trabalho, o objetivo é detectar os olhos em imagens faciais utilizando o TM através com algoritmos de otimização ABC e HS, analisando as vantagens e desvantagens de cada método.

As seções seguintes do artigo estão organizadas da seguinte forma: uma breve revisão sobre trabalhos relacionados e os principais técnicas e algoritmos utilizados no trabalho se encontram na Seção 2; o processo de detecção dos olhos é apresentado na Seção 3; os resultados são apresentados na Seção 4; e finalmente, a conclusão baseada nos experimentos e seus resultados é apresentada na Seção 5.

2. REVISÃO DA LITERATURA

Nesta seção são apresentados conceitos que foram utilizados neste projeto de pesquisa e alguns trabalhos correlatos desenvolvidos por outros pesquisadores e que serviram de embasamento teórico para o desenvolvimento deste trabalho.

2.1 Reconhecimento Facial

O reconhecimento facial (RF) vem sendo cada vez mais utilizado nas mais diversas áreas e se tornou um importante artefato para a segurança. O reconhecimento facial na área policial é utilizado para identificar as pessoas que praticam algum tipo de ato ilícito, em especial aquelas que já têm ficha policial cuja face se encontra na base de imagens. Além disto, o reconhecimento facial poderia ser utilizado na área de segurança privada como artefato de acesso a lugares restritos a algumas pessoas.

O RF abrange diversas etapas, desde a captura das imagens para treinamento do sistema até a fase de reconhecimento em si. Dentre estas etapas estão: detecção da face (ou elementos específicos da face, como os olhos, assim como é abordado neste trabalho), normalização da face, extração de características e o próprio reconhecimento [7, 8].

A detecção dos olhos é a mais importante de todas as etapas, pois a maioria das etapas seguintes depende da localização do olho. Portanto, é necessário localizar os olhos primeiro, assim como seu grau de rotação e sua variação em relação à escala para que a face seja normalizada. A extração de características, geralmente, é feita em regiões de interesse como olhos, nariz e boca [8].

2.2 *Template Matching*

Uma das técnicas que pode ser utilizada para realizar a detecção de olhos, ou outro objeto de interesse na imagem, é o *Template Matching* (TM). O principal objetivo do TM é encontrar um padrão em algum lugar de uma imagem, fazendo a correlação entre as duas imagens. O padrão que se deseja encontrar é conhecido como Imagem de Referência (IR) e a imagem na qual o padrão deve ser localizado é chamada de Imagem de Paisagem (IP) [9]. Em particular, neste trabalho a IR é o olho, e aqui chamada de Imagem-Olho de referência (IOR), enquanto que a IP da face humana é chamada de Imagem-Face (IF). Esta terminologia será utilizada ao longo deste artigo.

O processo de TM é feito usando o recorte de imagem feita na IF (no mesmo tamanho da IOR) e a IOR. Na IF, cada pixel pode ser uma coordenada central (x, y) do objeto a ser reconhecido. A vantagem de utilizar uma metodologia como esta é que não é necessário a segmentação da imagem. Uma desvantagem do TM é que o padrão que se deseja encontrar pode estar em qualquer lugar da IF, sendo, portanto, necessário buscar em toda a IF. Além disto, o padrão pode ter sofrido rotação e/ou escala, o que torna processo de busca complexo e custoso computacionalmente, pois além das coordenadas x e y da localização planar, deve-se determinar também os fatores de rotação e escala. De modo geral, métodos baseados em correlação como TM são muito dependentes de iluminação, rotação e escala [10].

Considerando todos estes fatores, o número de recortes possíveis numa imagem (espaço de busca) pode ser intratavelmente grande. Para realizar uma busca mais eficiente em tempo aceitável, utilizou-se os algoritmos de otimização ABC e HS implementados por [11] e [12], respectivamente.

2.3 Algoritmos de Otimização

Os algoritmos de otimização são um conjunto de técnicas de busca por possíveis soluções para problemas complexos. Muitas vezes tais algoritmos são inspirados na natureza. Para esta classe de algoritmos, utilizam-se populações de indivíduos no processo de busca, onde cada indivíduo pode ser uma possível solução para o problema. A ideia principal é evoluir, de alguma maneira, os indivíduos através de operações entre eles e da aplicação de princípios da evolução natural. A qualidade do indivíduo, enquanto

solução do problema, é calculada através de uma função chamada de *fitness*, que mede a adequação do indivíduo. Assim sendo, o algoritmo é executado algumas vezes procurando por uma solução que melhor represente a resposta do problema [5].

Diversas fontes de inspiração na natureza foram utilizadas para o desenvolvimento dos algoritmos evolucionários. Um dos mais conhecidos e utilizados é o Algoritmo Genético (AG) proposto por [13], baseado na codificação genética das espécies. Neste algoritmo uma possível solução é análoga a um cromossomo biológico. Nos AGs a população inicial é formada por vários indivíduos (cromossomos) que são submetidos a evolução, sendo que uma parte da população é selecionada para próxima geração, gerando filhos através de cruzamento e mutação, os principais operadores do AG. Karungaru [14] propôs um trabalho sobre reconhecimento facial baseado no *Template Matching* otimizado com Algoritmos Genéticos. Este autor utilizou um *template* em "T" formado por olhos, nariz e boca para realizar o RF.

O comportamento de grupos de animais também foi fonte de inspiração para Eberhart et al. [15], que propuseram algoritmos que levam o nome de algoritmos de inteligência coletiva. Os principais algoritmos baseados nesta ideia são os de colônia de formigas (ACO - *Ant Colony Optimization*), colônia de abelhas (ABC - *Artificial Bee Colony*) [16] e por enxame de partículas (PSO - *Particle Swarm Optimization*) [15]. O ACO usa a comunicação através de trilhas de feromônio para indicar caminhos para fontes de alimentos. O PSO utiliza a ideia de boas experiências que são comunicadas entre indivíduos, fazendo com eles busquem conhecimento. Perlin [9, 17] utilizou PSO para otimizar a técnica de TM para o reconhecimento de objetos. O ABC utiliza a busca e coleta por alimento como ideia central. Este algoritmo foi usado por [18] para otimizar o processo de reconhecimento de objetos presentes num imagem de paisagem usando o TM. Da mesma forma, o ABC também foi utilizado em estudos de detecção de íris por [19].

A música também foi utilizada para formular metodologias inteligentes de busca, como é o exemplo do *Harmony Search* (HS) proposto por [6]. O HS utiliza a ideia do improviso de novos sons musicais para o encontro de uma harmonia perfeita. Scalabrin [12] utilizou o HS para otimizar processos de *benchmark*.

Neste trabalho, ABC e HS foram utilizados para buscar com mais eficiência no espaço de busca nas imagens. As seções a seguir explicam o funcionamento destes algoritmos.

2.4 *Harmony Search*

O primeiro algoritmo de otimização que foi utilizado neste trabalho é o *Harmony Search* (HS), conforme proposto por [6], tendo como inspiração o arranjo de harmonias de um trio de jazz. A harmonia musical é um conjunto de sons que seja agradável ao ouvido humano. As harmonias são combinações de várias ondas de sons que possuem diferentes frequências [6].

Assim como outros algoritmos de otimização que buscam a melhor solução determinada por uma função objetivo, o HS busca a melhor harmonia de acordo com uma estimativa estética. Esta estimativa estética é dada pelos sons emitidos através dos instrumentos dos músicos e os sons podem ser melhorados através de prática. Os passos do algoritmo *Harmony Search* podem ser mostrados a seguir:

1. Inicializar o problema.
2. Inicializar a Memória Harmônica (HM - *Harmony Memory*).
3. Improvisar uma nova harmonia.
4. Se a nova harmonia é melhor que a mínima na HM
 - (a) Incluir a nova harmonia e excluir a mínima da HM.
5. Se o critério de parada não estiver satisfeito
 - (a) Voltar para o passo 3.

Os principais parâmetros deste algoritmo são o número de execuções e o número de músicos. O primeiro é o número de gerações que o algoritmo vai executar para encontrar a harmonia perfeita e o segundo representa o número de variáveis presentes no problema.

Estes parâmetros são: o HMCR (*Harmony Memory Considering Rate*) e o PAR (*Pitch Adjusting Rate*). O HMCR é utilizado quando não existe partes da solução global na Memória Harmônica. Quando este parâmetro é ativado o *Harmony Search* encontra notas de forma aleatória dentre as notas possíveis para o problema. O HMCR pode variar entre 0 e 1, por exemplo, quando o valor for igual a 0,8 significa que o HS escolhe um valor para certa variável com 80% de probabilidade. Por outro lado, o PAR é uma taxa de ajuste do passo para que o algoritmo não fique parado em um ponto de máximo/mínimo local. Este valor é o deslocamento de valores vizinhos dentro de um intervalo. Quando o valor do PAR é 0,1 significa que a probabilidade de se escolher um valor vizinho é de 10%. [6, 12]

2.5 *Artificial Bee Colony*

Os principais componentes que formam o algoritmo ABC são as fontes de comida, as abelhas empregadas e as abelhas desempregadas, estas podem ser classificadas em escoteiras e observadoras [20]. As abelhas empregadas levam informações para as abelhas observadoras sobre fontes de comida e transmitem esta informação através da dança. As abelhas escoteiras procuram

aleatoriamente por novas fontes de comida, enquanto que as observadoras decidem sobre o que fazer com a informação obtida através da dança.

O algoritmo ABC é mostrado simplificada e a seguir:

1. Inicializar a População de tamanho SN.
2. Repetir até MCN:
 - (a) Posicionar abelhas empregadas no espaço de busca.
 - (b) Posicionar abelhas observadoras nas fontes de acordo com quantidade de néctar (transmitida pela dança).
 - (c) Determinar fontes de alimento a serem abandonadas.
 - (d) Enviar abelhas escoteiras para procurar novas fontes.
 - (e) Memorizar a melhor fonte que foi encontrada até o momento.
3. Fim.

O processo é executado por um Número Máximo de Ciclos (MCN - *Maximum Cycle Number*), ou até o critério de parada ser encontrado. O número de abelhas presentes na colônia é representado por SN.

Na etapa 1 a população é iniciada com SN abelhas e fontes de alimentos aleatórias são escolhidas. Na etapa 2a as abelhas empregadas são posicionadas nestas fontes. As abelhas voltam à colmeia e transmitem, através da dança, informações para as abelhas observadoras. As abelhas empregadas voltam para as fontes de alimento para selecionar novas fontes e novamente transmitir informações para as observadoras. Na etapa 2b as observadoras decidem, através de informações obtidas, para qual fonte de alimento elas irão, então elas são posicionadas nestas fontes e também procuram por novas fontes. Quando uma fonte se torna baixa ela é abandonada, etapa 2c. Em cada ciclo pelo menos uma abelha escoteira vai à procura de novas fontes de alimento para substituir a que foi abandonada (2d). A melhor fonte encontrada é memorizada (2e) e o processo começa novamente da etapa 2a até o critério de parada ser atingido ou até o valor de MCN.

3 PROCESSO DE DETECÇÃO DE OLHOS

O processo de detecção de olhos foi feito com a aplicação do algoritmo TM. A solução para esse problema é composta por 4 valores, sendo dois deles a localização espacial (eixos x e y) da imagem de recorte. Esses valores são variáveis de 0 até o tamanho da imagem (largura e altura). Os outros 2 valores são os fatores de rotação (θ) e escala (e). O valor de rotação pode variar entre $-\pi/2$ e $\pi/2$ e a escala entre 0,5 e 1,5.

Como o TM consta de uma busca exaustiva, esta técnica foi melhorada com os algoritmos de otimização HS e ABC. No HS as variáveis x , y , θ e e são representadas por uma harmonia. E no ABC uma abelha indica o conjunto das variáveis. Tanto a harmonia quanto a abelha indicam a imagem recorte feita na IF através do TM.

Os algoritmos HS e ABC, antes implementados para reconhecimento de objetos, foram adaptados para receber o problema de detecção. As alterações principais foram em relação ao tamanho das imagens de entrada (IF e IOR). E ainda os parâmetros foram modificados no decorrer dos testes.

Para testes iniciais foram utilizadas imagens faciais controladas da base *FEI Face Database* [21], as imagens desta base possuem 640 X 480 pixels. Em seguida foram utilizadas imagens capturadas para execução este estudo, com o tamanho de 1400 X 1050 pixels. Algumas destas imagens podem ser vistas na Figura 1. As IORs foram extraídas manualmente das imagens capturadas para a realização dos testes, da uma possui 143 X 68 pixels. Como as IORs foram extraídas manualmente já foram estabelecidos os valores esperados da posição (x,y) dos recortes, onde a imagem do olho ficasse centralizada.



Figura 1: Imagens de Referência

4. EXPERIMENTOS E RESULTADOS

Para realizar os testes foram utilizados algoritmos implementados em C. Para os testes do algoritmo HS os parâmetros foram iniciados com base nos estudos de Geem [22] e os parâmetros do ABC foram iniciados de acordo com sugestões de Karaboga e Akay [23]. Exemplos de testes estão descritos nesta seção e os resultados são apresentados em tabelas. As IFs utilizadas nos testes são apresentadas na Figura 1.

Os parâmetros para o algoritmo ABC para os primeiros testes (Teste1) foram: MCN igual a 200 e SN igual a 10, onde uma abelha é a escoteira. Em seguida foram feitos testes com MCN igual a 20 e SN igual a 100 (Teste2). Para cada teste o algoritmo foi executado 30 vezes. Na Tabela 1 $\bar{d}E$ é a média da distância Euclidiana dos pontos encontrados em relação aos pontos reais (manualmente determinados). Para estes testes as IFs estão sem rotação e mudança de escala.

Tabela 1: Soluções encontradas pela execução do TM com ABC (valores médios)

<i>IR</i>	$\bar{d}E$ (Teste1)	Avaliações	$\bar{d}E$ (Teste2)	Avaliações
1(a)	40 ± 29	9900 ± 961	9 ± 3	5324 ± 907
1(b)	158 ± 40	10160 ± 2285	51 ± 50	5957 ± 1128
1(c)	64 ± 50	10400 ± 2581	11 ± 23	5421 ± 1157
1(d)	76 ± 69	10305 ± 2219	6 ± 4	5863 ± 1704
1(e)	131 ± 118	10350 ± 2094	7 ± 11	5395 ± 1547
1(f)	66 ± 66	10735 ± 2575	4 ± 3	5354 ± 1141
1(g)	78 ± 81	10670 ± 2209	11 ± 27	5729 ± 1175
1(h)	45 ± 46	10620 ± 1930	15 ± 4	5538 ± 1396
Média		10392		5572

Como é possível observar nesta tabela (1) os resultados do Teste2 foram melhores. Mais valores do Teste2 do que do Teste1 se aproximaram do esperado. O Teste1 mostra que um número menor de abelhas faz com que o algoritmo não seja tão eficiente, pois não é feita uma busca global tão ampla pelo espaço de busca antes de ser feita uma busca mais localizada. Observando os dois testes é possível verificar que a segunda IF (1(b)) é a que mostrou maior distância Euclidiana. Isso ocorreu porque o algoritmo identificou o cabelo como um ponto de mínimo local na maioria das rodadas, por ele conter muitos pixels semelhantes com a IOR, não conseguindo chegar ao ótimo global.

Alguns testes foram realizados para o HS com os parâmetros definidos como segue. No Teste1 o HMCR foi igual a 0,1 e o PAR igual a 0,9, caracterizando uma busca aleatória. No Teste2 o HMCR foi definido como 0,9 e o PAR 0,2. Os resultados destes testes, também sem rotação e escala, são, mostrados na Tabela 2.

Tabela 2: Soluções encontradas pela execução do TM com HS (valores médios)

<i>IR</i>	$\bar{d}E$ (Teste1)	Avaliações	$\bar{d}E$ (Teste2)	Avaliações
1(a)	7 ± 1	57432 ± 25568	7 ± 0, 2	47905 ± 24317
1(b)	6 ± 1	66190 ± 25931	5 ± 0, 2	23016 ± 24361
1(c)	6 ± 1	67460 ± 21914	7 ± 0, 3	46585 ± 33214
1(d)	5 ± 1	69560 ± 18214	5 ± 0, 5	25023 ± 16400
1(e)	3 ± 1	60150 ± 27335	251 ± 220	9859 ± 14523
1(f)	3 ± 1	67514 ± 27618	3 ± 0, 2	20701 ± 17739
1(g)	3 ± 1	73519 ± 17568	4 ± 0, 2	18544 ± 15584
1(h)	15 ± 1	60481 ± 23520	15 ± 0, 2	10513 ± 12762
Média		65288		25268

A Tabela 2 mostra que em ambos os testes o algoritmo HS foi eficiente. Porém, no primeiro foi necessário um número maior de avaliações para encontrar a IOR, devido às configurações de parâmetros, levando o algoritmo a privilegiar uma busca mais global. No segundo teste o olho não foi detectado na imagem 1(e) e, sim, o queixo do indivíduo, pois ele está com um pouco de sombra em um dos olhos, fazendo com que o algoritmo encontrasse parte da barba, também sombreada, pela similaridade dos pixels.

Testes com as IFs sofrendo rotação e escala também foram feitos. Todas as imagens foram submetidas a uma redução de 15%, ou seja, a escala esperada pela execução do algoritmo é 0,85. As 4 primeiras imagens foram submetidas a uma rotação de 20° e as outras de -20°. Sendo assim o valor esperado é 0,35 e -0,35, 20° e -20° em radianos respectivamente. Para estes testes o algoritmo foi executado 30 vezes. A seguir são mostrados os resultados das execuções do TM com ABC (Tabela 3) e com o HS (Tabela 4). Nas tabelas são mostradas a média e desvio padrão das distâncias euclidianas dos valores obtidos com os esperados, ainda é possível ver a rotação e escala obtidos com cada IF.

Tabela 3: Soluções encontradas pela execução do TM com ABC para as IFs com rotação e escala (valores médios)

<i>IR</i>	\bar{dE}	θ	<i>e</i>	Avaliações
1(a)	$8 \pm 0,5$	$0,36 \pm 0,01$	$0,85 \pm 0,01$	48476 ± 2533
1(b)	129 ± 9	$-0,97 \pm 0,07$	$0,51 \pm 0,03$	51598 ± 8951
1(c)	18 ± 36	$0,38 \pm 0,17$	$0,83 \pm 0,08$	48164 ± 9574
1(d)	2 ± 1	$0,33 \pm 0,04$	$0,85 \pm 0,02$	50224 ± 8652
1(e)	14 ± 52	$-0,35 \pm 0,02$	$0,83 \pm 0,05$	49300 ± 3698
1(f)	10 ± 22	$-0,35 \pm 0,02$	$0,85 \pm 0,08$	42092 ± 10917
1(g)	5 ± 1	$-0,36 \pm 0,01$	$0,85 \pm 0,01$	50636 ± 7295
1(h)	11 ± 2	$-0,35 \pm 0,01$	$0,86 \pm 0,03$	48714 ± 8821
Média				48650

Os parâmetros para este teste foram definidos como 100 e 200 para número de abelhas e número de gerações, respectivamente. Nesta tabela (3) pode-se notar que os olhos foram encontrados nas IFs, porém não totalmente centralizados. Com exceção da IF 1(b), nesta imagem o algoritmo está encontrando o cabelo ao lado esquerdo do olho. Nas imagens 1(c), 1(e) e 1(f) o desvio padrão foi grande pelo fato de em uma das 30 rodadas a distância Euclidiana ter sido maior que 100, caracterizando que não foi encontrado o olho. Porém, nas outras 29 rodadas o algoritmo foi eficiente.

Tabela 4: Soluções encontradas pela execução do TM com HS para as IFs com rotação e escala (valores médios)

<i>IR</i>	\bar{dE}	θ	<i>e</i>	Avaliações
1(a)	163 ± 185	$0,12 \pm 0,3$	$0,88 \pm 0,02$	86930 ± 18365
1(b)	139 ± 165	$0,61 \pm 0,7$	$0,90 \pm 0,25$	71290 ± 31340
1(c)	20 ± 36	$0,18 \pm 0,5$	$0,81 \pm 0,1$	83650 ± 18493
1(d)	59 ± 96	$0,37 \pm 0,1$	$0,77 \pm 0,1$	88367 ± 13756
1(e)	115 ± 145	$-0,08 \pm 0,5$	$0,88 \pm 0,22$	92431 ± 7646
1(f)	129 ± 117	$0,31 \pm 0,6$	$0,73 \pm 0,15$	75737 ± 27493
1(g)	5 ± 1	$-0,37 \pm 0,02$	$0,83 \pm 0,04$	90917 ± 8676
1(h)	11 ± 1	$-0,34 \pm 0,04$	$0,84 \pm 0,03$	90100 ± 9918
Média				84927

Os resultados equivalentes à tabela 4 foram obtidos com HMCR igual a 0,7 e o PAR igual a 0,5. Com a execução do HS com esta configuração é possível notar que o algoritmo não foi eficiente. Apesar disto, as últimas 2 imagens tiveram o olho detectado e em algumas imagens o olho foi detectado em menos da metade das execuções. Porém, as médias não ficaram de acordo com o esperado.

5. CONCLUSÃO

A proposta deste trabalho foi desenvolver um método de busca dos olhos numa imagem de face humana. A técnica utilizada foi o *Template Matching*, baseada na correlação entre imagens. Para otimizar esta técnica foram utilizados algoritmos de Computação Evolucionária, um baseado na música, o *Harmony Search* e outro baseado no comportamento de abelhas, o algoritmo de Colônia Artificial de Abelhas.

Com a execução dos testes foi possível notar que ambos os algoritmos foram eficientes para a detecção dos olhos. Em alguns casos o ABC foi melhor do que o HS, como é o exemplo das imagens sofrendo rotação e translação. O HS chegou a resultados mais próximos do esperado para as imagens sem rotação e escala. Porém, o número médio de avaliações foi entre 2 e 5 vezes maior que o ABC.

Com este trabalho foi possível notar que muitas vezes pequenos detalhes podem dificultar a detecção dos olhos. Como ocorreu nos testes, quando existia sombra nos olhos o algoritmo encontrava similaridade dos pixels com cabelo ou barba. Outro ponto que dificultou a detecção foi em função dos vários ótimos locais que o algoritmo interpreta, como exemplo cabelos, sobrancelhas e barba. Para encontrar o olho é necessário explorar globalmente o espaço de busca procurando ótimos locais, pois não existe uma tendência para o ótimo global (olho).

De modo geral, o algoritmo ABC foi mais eficiente que o HS. Apesar do HS ter detectado os olhos na maioria das execuções, em algumas não detectava, e ainda, o número médio de avaliações foi maior que do algoritmo ABC. O ABC realizou uma maior busca global no início da execução para depois uma busca localizada, fazendo com que os olhos fossem detectados em situações adversas, com rotação e escala.

6. AGRADECIMENTOS

Aos voluntários que participaram da captura das imagens faciais. E ao colega Marlon Henrique Scalabrin por disponibilizar o algoritmo *Harmony Search* para o desenvolvimento desta pesquisa.

REFERÊNCIAS

- [1] L. Ke and Y. Huang. “Eyes Location based on Dual-orientation Gabor Filters and Templates”. *2nd International Congress on Image and Signal Processing*, pp. 1–4, 2009.
- [2] K. I. Chang, K. W. Bowyer and P. J. Flynn. “Face Recognition Using 2D and 3D Facial Data”. *ACM Workshop on Multimodal User Authentication*, pp. 25–32, 2003.
- [3] L. Cole, D. Austin and L. Cole. “Visual Object Recognition using Template Matching”. *In Proceedings of Australian Conference on Robotics and Automation*, 2004.
- [4] R. Brunelli. *Template Matching Techniques in Computer Vision: Theory and Practice*. Wiley, 2009.
- [5] T. Bäck, U. Hammel and H.-P. Schwefel. “Evolutionary Computation: Comments on the History and Current State”. *IEEE Transactions on Evolutionary Computation*, vol. 1, pp. 3–17, 1997.
- [6] Z. W. Geem, J. Kim and G. V. Hoon, Longanathan. “A New Heuristic Optimization Algorithm: Harmony Search”. *Simulation. Transactions of the Society for Modeling and Simulation International*, vol. 76, no. 2, pp. 60–68, 2001.
- [7] D. Reissfeld and Y. Yeshurun. “Preprocessing of Face Images: Detection of Features and Pose Normalization”. *Computer Vision and Image Understanding*, vol. 71, pp. 413–430, 1998.
- [8] W. Zhao, R. Chellappa, P. J. Phillips and A. Rosenfeld. “Face Recognition: A Literature Survey”. *ACM Computing Surveys*, vol. 35, pp. 399–458, 2003.
- [9] H. A. Perlin, H. S. Lopes and T. M. Centeno. “Particle Swarm Optimization for Object Recognition in Computer Vision”. *21st international conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*, pp. 11–21, 2008.
- [10] L. O. Marin. “Métodos Estatísticos no Reconhecimento de Faces”. *Revista Eletrônica de Sistemas de Informação (RESI)*, vol. 8, no. 2, 2006.
- [11] 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*, vol. 1, no. 2, pp. 54–70, 2010.
- [12] M. H. Scalabrin, R. S. Parpinelli and H. S. Lopes. “Paralelização do Algoritmo Harmony search utilizando Unidade de Porocessamento Gráfico”. *Mecânica Computacional*, vol. 29, pp. 7109–7121, 2010.
- [13] D. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, 1989.
- [14] S. Kaungaru, M. Fukumi and N. Akamatsu. “Face Recognition using Genetic Algorithm based Template Matching”. *International Symposium on Communications and Information Technologicis*, vol. 2, pp. 1252–1257, 2004.
- [15] R. C. Eberhart, Y. Shi and J. Kenedy. *Swarm Intelligence*. Morgan Kaufmann, San Francisco, 2001.
- [16] D. Karaboga. “An idea based on Honey Bee Swarm for Numerical Optimization”. Technical Report TR-06, Erciyes University - Engineering Faculty, October 2005.
- [17] H. A. Perlin. “Reconhecimento de Objetos em Imagens Digitais Utilizando Otimização por Enxame de Partículas”. Masters thesis, Universidade Tecnológica Federal do Paraná, 2009.
- [18] C. Chidambaram and H. S. Lopes. “A New Approach for Template Matching in Digital Images Using an Artificial Bee Colony Algorithm”. *Nature & Biologically Inspired Computing World Congress*, pp. 146–151, 2009.
- [19] J. C. S. J. Junior, J. L. Moreira, A. Braun and S. R. Musse. “A Template-matching Based Method to Perform Iris Detection in Real-time Using Synthetic Templates”. *11th IEEE International Symposium on Multimedia*, pp. 142 – 147, 2009.
- [20] V. Tereshko and A. Loengarov. “Collective Decision-Making in Honey Bee Foraging Dynamics”. *Coomputing and Information Systems*, vol. 9, no. 3, pp. 1–7, 2005.
- [21] L. L. de Oliveira Junior and C. E. Thomaz. “Captura e Alinhamento de Imagens: Um Banco de Faces Brasileiro”. Final report, Centro Universitário da FEI, 2005.

- [22] Z. W. Geem. *Recent Advances in Harmony Search Algorithm*. Springer, Berlin, 2010.
- [23] D. Karaboga and B. Akay. “A comparative study of Artificial Bee Colony algorithm”. *Applied Mathematics and Computation*, vol. 214, pp. 108–132, 2009.