

# Floresta de Caminhos Ótimos aplicado ao Reconhecimento Biométrico Multimodal

Daniel M. M. da Costa, Sarajane M. Peres, Clodoaldo A. M. Lima  
Programa de Pós-Graduação em Sistemas de Informação  
Escola de Artes, Ciências e Humanidades  
Universidade de São Paulo  
São Paulo, SP, Brasil  
E-mail: {daniel.moura.costa,sarajane,c.lima}@usp.br

**Resumo**—Devido a crescente exigência de se estabelecer a identidade dos indivíduos, várias estratégias têm sido propostas visando superar as limitações da abordagem tradicional baseada em senha, tokens, etc. Dentre estas estratégias destaca-se a Biometria, esta emprega características físicas ou comportamentais do usuário para realizar seu reconhecimento. Íris e face estão entre as modalidades mais promissoras que podem identificar com precisão uma pessoa. Sistemas de Reconhecimento Biométrico Unimodal, os quais empregam apenas uma modalidade biométrica, baseado em face ou íris restringem o domínio de aplicação a cenários ideais. Estas limitações podem ser superadas com o uso dos Sistemas de Reconhecimento Biométrico Multimodal, o qual faz a combinação de duas ou mais características para realizar o reconhecimento dos usuários. Este artigo realiza um estudo comparativo das diversas técnicas de fusão no nível de característica, utilizando o classificador Floresta de Caminhos Ótimos. Para extração de características foi utilizada transformada Wavelet. Os resultados demonstram que os sistemas multimodais, dependendo da estratégia de fusão e da métrica de distância utilizada no classificador, são capazes de produzir taxas de reconhecimento mais altas quando comparado com os sistemas unimodais.

**Palavras-Chave**—Floresta de Caminhos Ótimos, Transformada Wavelet, Reconhecimento Biométrico Multimodal.

## I. INTRODUÇÃO

Com o avanço da tecnologia, as estratégias tradicionais de identificação vêm sofrendo com problemas de invasão e gerando dúvidas sobre sua capacidade de segurança. Com isso, pesquisas envolvendo novas estratégias têm sido realizadas pela indústria e comunidade científica [1], sendo a Biometria, utilização de características físicas e comportamentais de um usuário para sua identificação, uma área que vem recebendo uma grande atenção. Dentre as modalidades biométricas destacamos a íris [2], impressão digital [3] e face [4]. Para que uma característica possa ser considerada uma modalidade biométrica é necessário que alguns requisitos sejam satisfeitos [5]: universalidade, distinção, circunvenção, mensurabilidade, desempenho e aceitabilidade.

Um sistema biométrico pode ser dividido em quatro módulos [1]: Módulo Sensorial, o qual realiza a captura do dado de entrada; Módulo de Extração de Característica, que extrai a informação útil do dado de entrada; Módulo de Comparação, que compara a informação de entrada com os padrões armazenados; Módulo de Decisão, que recebe a saída do classificador e gera uma decisão final. Na Figura 1 apresentamos a estrutura de um sistema biométrico.

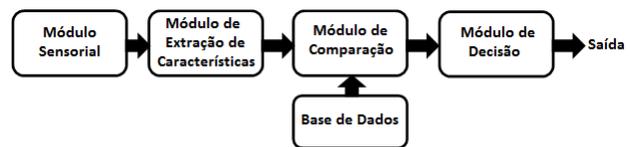


Fig. 1. Estrutura de um Sistema Biométrico.

Os primeiros sistemas biométricos propostos foram os sistemas biométricos unimodais, os quais utilizam apenas uma modalidade biométrica para reconhecer o usuário. Apesar desses sistemas apresentarem desempenho satisfatório em diversas aplicações, alguns problemas ainda são enfrentados, tais como, [6]: i) Dados de entrada ruidosos; ii) Variações intraclasse; iii) Similaridade interclasses; iv) Não-universalidade; v) Possibilidade de falsificação. De forma a superar essas limitações foram propostos os sistemas biométricos multimodais, os quais combinam duas ou mais modalidades biométricas para gerar sistemas mais robustos e confiáveis.

Os sistemas biométricos multimodais podem ser categorizados de acordo com a sua arquitetura, nível de fusão e estratégia de fusão [7]. Sendo que um dos principais pontos é a estratégia de combinação dessas modalidades. Neste trabalho será realizado a combinação de duas modalidades biométricas, face e íris, no nível de característica.

De forma a gerar um vetor de características que represente melhor os dados de entrada pode se utilizar alguma estratégia de extração de características, sendo que a transformada Wavelet (WT) [8] é mais comumente utilizada. WT é uma técnica de processamento de sinais que realiza a decomposição de um determinado sinal em um conjunto de coeficientes que representam os dados originais.

Recentemente, um novo framework para classificadores baseado em grafos, que reduz o problema de reconhecimento padrão para o cálculo de uma Floresta de Caminhos Ótimos (OPF - Optimum-Path Forest) no espaço de característica induzido por um grafo, foi proposto por [9]. Este tipo de classificador não interpreta a tarefa de classificação como problema de otimização de um hiperplano, mas como cálculo combinatorial de caminho ótimo a partir de alguns exemplos chaves (protótipos) para os nós restantes. Esses classificadores vêm sendo utilizados em diferentes contextos [10], incluindo Biometria [11]. Em [11], os autores compararam o desempenho de Máquinas de Vetores Suporte, Redes Neurais

Artificiais e OPF para reconhecimento baseado em íris, sendo que o OPF apresentou melhor desempenho.

O OPF apresenta as seguintes vantagens em relação aos classificadores tradicionais [10]: (i) necessário configurar apenas um parâmetro (métrica de distância); (ii) não assume separabilidade dos dados no espaço de característica; (iii) processo de treinamento rápido, permitindo o seu uso em aplicações de tempo real; e (iv) realiza a classificação através de um processo de otimização global.

Neste trabalho realizamos um estudo comparativo entre técnicas de fusão no nível de característica para reconhecimento biométrico baseado em face e íris, utilizando o classificador OPF com diferentes métricas de distância. De forma a avaliar o desempenho obtido com a metodologia proposta, foi utilizada uma base de dados pública, chamada *SDUMLA-HMT Database* [12].

Nas Seções II e III introduzimos os sistemas biométricos unimodais e multimodais. Seção IV descreve a transformada Wavelet, utilizada para extração de característica. Já na Seção V descrevemos o classificador OPF. Os resultados obtidos foram descritos na Seção VI. Uma breve conclusão e os próximos passos foram descritos na Seção VII.

## II. SISTEMAS BIOMÉTRICOS UNIMODAIS

Os primeiros sistemas biométricos propostos foram os chamados sistemas biométricos unimodais [5], que empregam uma única modalidade biométrica para fazer o reconhecimento do usuário. Sendo a íris e face modalidades promissoras para a identificação de uma pessoa, visto que suas características únicas podem ser rapidamente extraídas durante o processo de reconhecimento. Neste artigo projetamos um Sistema Unimodal e Multimodal utilizando essas características.

Um sistema biométrico baseado em face utiliza uma câmera para capturar a imagem contendo a face do usuário, em seguida realiza a detecção da face nessa imagem, onde um conjunto de características é extraído e utilizado como entrada para um classificador realizar o reconhecimento. Realizamos a detecção das faces nas imagens utilizando o Algoritmo de Viola-Jones [13], esse algoritmo faz o uso de características de Haar e um classificador em cascata para localizar a região contendo a face. Na Figura 2 temos alguns exemplos de face detectada usando esse algoritmo.



Fig. 2. Exemplo de faces detectadas usando o Algoritmo de Viola-Jones.

Os sistemas biométricos baseados em íris utilizam um sensor de íris ou uma câmera de alta definição para capturar a imagem do olho, então um algoritmo para localização e segmentação da íris é utilizado para detectar a região de interesse, onde o conjunto de características é extraído e utilizado como entrada para um classificador. De forma a segmentar a região da íris, utilizamos o algoritmo proposto

por Wildes e Camus [14]. A imagem segmentada é convertida para coordenadas polares [15]. Na Figura 3 temos um exemplo do processo de segmentação e extração da íris.



Fig. 3. Exemplo de segmentação e extração da íris.

O Método de Wildes e Camus [14] realiza a detecção da íris e da pupila empregando um detector de borda, seguido pela transformada de Hough. Esse método retorna um conjunto de pontos  $(x, y, r_i, r_p)$ , onde  $(x, y)$  é o centro do olho,  $r_i$  é o raio da íris e  $r_p$  é o raio da pupila. Baseado nesse conjunto de pontos detectados, a imagem da íris segmentada é convertida para coordenadas polares. Esse procedimento é descrito pelas equações 1 e 2.

$$x(r, \theta) = (1 - r)x_p(\theta) + rx_s(\theta) \quad (1)$$

$$y(r, \theta) = (1 - r)y_p(\theta) + ry_s(\theta) \quad (2)$$

onde  $(x_p(\theta), y_p(\theta))$  são os limites da pupila,  $(x_s(\theta), y_s(\theta))$  são os pontos do perímetro da íris e  $r$  representa a distância entre  $r_p$  e  $r_i$ . A imagem polar  $I(r, \theta)$  pode ser descrita pela equação 3.

$$I(r, \theta) = I(x(r, \theta), y(r, \theta)) \quad (3)$$

## III. SISTEMAS BIOMÉTRICOS MULTIMODAIS

Os sistemas biométricos multimodais, os quais empregam duas ou mais modalidades biométricas [7], foram propostos de forma a superar as dificuldades enfrentadas pelos sistemas unimodais e apresentam as seguintes vantagens: i) Melhora do desempenho de reconhecimento; ii) Menor influência das variações do ambiente no sistema; iii) Reduz problemas relacionados a não-universalidade; iv) Dificulta os ataques por circunvenção e repetição.

De forma a construir um sistema biométrico multimodal é necessário definir: i) as modalidades que serão utilizadas, ii) o nível de fusão, e iii) a estratégia de fusão a ser adotada. Em [16] foram apresentados os diversos níveis de fusão para construção de sistemas biométricos multimodais. Neste trabalho será utilizado o nível de características.

### A. Estratégias para Combinação de Características

De forma a construir os sistemas biométricos multimodais é necessário definir a estratégia de fusão que será adotada. Em [17] foram apresentadas diversas estratégias de combinação usando como extrator de característica a transformada Wavelet. As estratégias realizavam a substituição dos coeficientes de uma modalidade biométrica pelos coeficientes de outra, gerando uma nova imagem, que é utilizada como entrada para o classificador.

De forma a trabalhar com um conjunto menor de características, realizamos uma alteração nas estratégias propostas e combinamos as características obtidas apenas do nível de decomposição wavelet igual a 3, ou seja, realizamos a fusão de sub-imagens de tamanho aproximado igual a

$\frac{n}{8} \times \frac{m}{8}$ , com  $n \times m$  representando a dimensão original da imagem, variando de acordo com a função Wavelet utilizada. As estratégias de fusão empregadas neste trabalho são as seguintes:

- *Estratégia #1* - Selecionamos os coeficientes de aproximação da face e concatenamos com os coeficientes de detalhes da íris;
- *Estratégia #2* - Selecionamos os coeficientes de aproximação da íris e concatenamos com os coeficientes de detalhes da face;
- *Estratégia #3* - Calculamos a média dos coeficientes de aproximação obtidas da íris e face e concatenamos com máximo dos coeficientes de detalhes entre a face e a íris;
- *Estratégia #4* - Selecionamos o mínimo dos coeficientes de aproximação entre a face e a íris e concatenamos com máximo dos coeficientes de detalhes entre a face e a íris;

Além dessas estratégias, utilizamos 4 estratégias de combinação adicionais, também envolvendo os seus coeficientes:

- *Estratégia #5 - Soma [18]*: Considerando duas modalidades biométricas,  $X$  e  $Y$ , geramos a fusão  $Z = \{Z_1, Z_2, \dots, Z_n\}$  como sendo  $Z_i = (X_i + Y_i)$ ;
- *Estratégia #6 - Soma Ponderada [18]*: Considerando duas modalidades biométricas,  $X$  e  $Y$ , geramos a fusão  $Z = \{Z_1, Z_2, \dots, Z_n\}$  como sendo  $Z_i = (\alpha * X_i + \beta * Y_i)$  onde  $\alpha + \beta = 1$ ;
- *Estratégia #7 - Preservação de Contornos [19]*: esta estratégia foi originalmente proposta para a transformada Contourlet. Considerando duas características biométricas,  $X$  e  $Y$ , aplica-se o detector de borda de Sobel e verifica as seguintes condições:
  - Se  $X(i, j) = 1 \Rightarrow C(i, j) = X(i, j)$ ;
  - Se  $Y(i, j) = 1 \Rightarrow C(i, j) = Y(i, j)$ ;
  - Se  $|X(i, j)| \geq |Y(i, j)| \Rightarrow C(i, j) = X(i, j)$ ;
  - Se  $|Y(i, j)| \geq |X(i, j)| \Rightarrow C(i, j) = Y(i, j)$ ;
- *Estratégia #8 - Concatenação [20]*: considerando duas modalidades biométricas,  $X$  e  $Y$ , geramos a fusão  $Z$  como sendo  $Z = \{X, Y\}$ ;

#### IV. TRANSFORMADA WAVELET

A ideia da transformada Wavelet é expressar um sinal, representado no domínio do tempo-frequência, como uma combinação linear de funções que são obtidas através da translação e dilatação de uma função específica, chamada *Função Wavelet Mãe*. Ao final desse processo são gerados os chamados coeficientes Wavelets, os quais podem ser utilizados para representar os dados originais.

Para calcular os coeficientes de Wavelets de um sinal podemos utilizar um par de filtros de Resposta Impulsiva Finita (Filtros FIR), um passa-baixa  $G$  e um passa-alta  $H$ . Esse processo é conhecido como Algoritmo de Mallat

[8]. A saída desse algoritmo é composta por dois novos sinais: coeficientes de aproximação, os quais representam as baixas frequências (obtido com o filtro  $G$ ), e coeficientes de detalhes, que representam as altas frequências (obtido com o filtro  $H$ ). Esse processo pode ser visto na Figura 4.

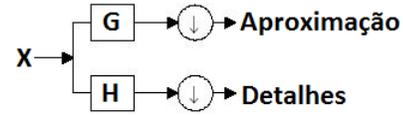


Fig. 4. Decomposição Wavelet 1D.

Para aplicar a transformada Wavelet em imagens pode-se realizar o mesmo procedimento descrito acima em dois momentos distintos, primeiro nas linhas e em seguida nas colunas da imagem. Esse processo é ilustrado na Figura 5(a) e gera ao final 4 sub-imagens (Figura 5(b)). As sub-imagens  $LL$  (coeficientes de aproximação) resultam da aplicação do filtro passa-baixa nas colunas e nas linhas, já as sub-imagens  $LH, HL$  e  $HH$  (coeficientes de detalhes) contém as altas frequências horizontais, verticais e diagonais respectivamente, representando a filtragem passa-alta  $H$  em pelo menos uma direção.

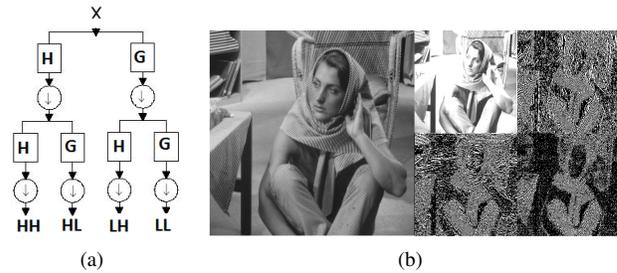


Fig. 5. (a) - Decomposição Wavelet 2D. (b) - Exemplo de Decomposição Wavelet 2D.

A transformada Wavelet pode ser aplicada em diferentes escalas, sendo o Método de pirâmide o mais comum [21]. Na decomposição em  $k$  níveis, um conjunto de sub-imagens  $LL_k, LH_k, HL_k, HH_k, LL_{k-1}, \dots, HH_1$  é gerado. Neste trabalho utilizamos 3 níveis de decomposição, as sub-imagens  $LL_3, LH_3, HL_3$  e  $HH_3$  foram utilizadas para representar as imagens.

#### V. FLORESTA DE CAMINHOS ÓTIMOS

Floresta de Caminhos ótimos (Optimum Path Forest - OPF) foi proposto em [9]. Neste modelo as instâncias de treinamento são nós de um grafo completo, com suas arestas representando a distância entre seus nós. Então os protótipos são identificados em todas as classes através da minimização da função de conectividade. Cada protótipo torna-se uma raiz da árvore de caminho mínimo e cada nó é classificado de acordo com o seu protótipo fortemente conectado. Este processo define uma partição ótima do espaço de característica. A classe dos dados na árvore de caminho mínimo é a classe da sua raiz. Este processo pode ser visto na Figura 6.

Durante o teste, o OPF avalia todos os caminhos ótimos dos protótipos até a nova instância, então a nova instância é classificada de acordo com o melhor caminho encontrado.

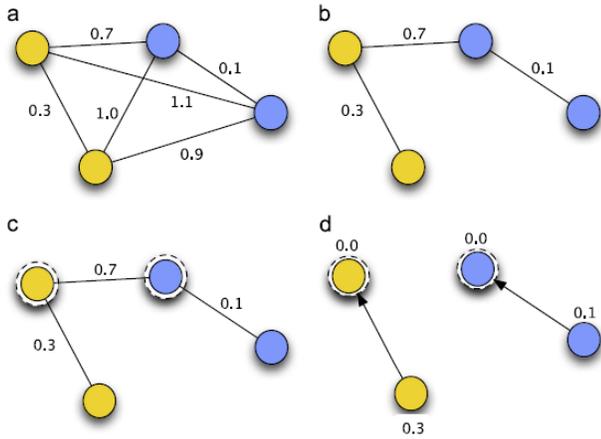


Fig. 6. Processo de treinamento do OPF. (a) Grafo completo, (b) Árvore Geradora Mínima, (c) Protótipos selecionados, (d) Floresta de Caminhos ótimos gerada [10]

Uma das características deste classificador é que a nova instância pode ser classificada como classe  $i$ , mesmo que uma instância da classe  $j$  esteja mais próxima. O processo de teste pode ser visto na Figura 7.

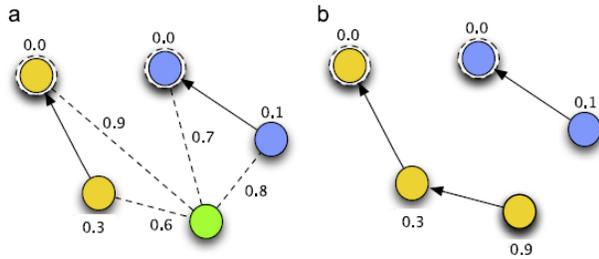


Fig. 7. Processo de teste do OPF. (a) Exemplos de teste são submetidos para o sistema e ligados para todos os nós gerados anteriormente, (b) Exemplo de teste é classificado de acordo para protótipo mais fortemente conectado.

Em [10] foi realizado um estudo comparativo entre o OPF e outras técnicas de classificação como Máquinas de Vetores Suporte e Redes Neurais para tarefa de diagnóstico de epilepsia através da classificação de sinais de eletroencefalograma. Os melhores resultados foram alcançados usando o OPF com métrica de distância Euclidiana, Manhattan e Chi-Quadrada. Em função desses resultados, essas métricas de distância foram empregadas neste trabalho. A formulação de cada métrica de distância usada pode ser visto na Tabela I. Nos experimentos reportados neste artigo utilizamos o LibOPF2, disponível em: <http://www.ic.unicamp.br/~afalcao/libopf/>.

TABELA I. MÉTRICAS DE DISTÂNCIA.

Métrica de Distância	Fórmula
Euclidiana	$D(x, y) = \sqrt{\sum_{i=1}^N (x_i - y_i)^2}$
Manhattan	$D(x, y) = \sum_{i=1}^N  x_i - y_i $
Chi-Quadrada	$D(x, y) = (\sum_{i=1}^N \frac{(x_i - y_i)^2}{x_i + y_i})^2$

## VI. RESULTADOS EXPERIMENTAIS

Nessa seção descrevemos em detalhes a base de dados utilizada, a configuração adotada nos experimentos e os resultados obtidos.

### A. SDUMLA-HMT Database

De forma a verificar o desempenho do classificador OPF, será utilizado à base de dados SDUMLA-HMT. Essa base de dados consiste das seguintes modalidades biométricas: face, veias dos dedos, forma de caminhar, íris e impressão digital de 106 pessoas (61 homens e 45 mulheres com idade entre 17 e 31 anos).

A base de dados de face contém 84 imagens coloridas por usuário, composta por 12 diferentes configurações. A base de dados contém 8904 imagens no total, com dimensão de  $640 \times 480$  pixels. Já base de dados de íris é composta por 10 imagens por usuário, sendo 5 para cada íris em escala de cinza com dimensão de  $768 \times 576$  pixels, contendo 1060 imagens no total. Alguns exemplos dessas imagens podem ser vistas na Figura 8.

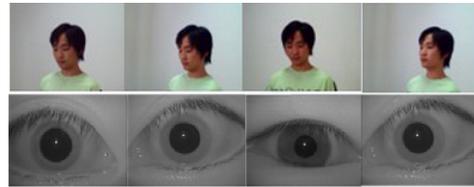


Fig. 8. Exemplos de imagens de face e íris da base de dados SDUMLA-HMT.

### B. Configuração dos Experimentos

Conforme mencionado anteriormente, a detecção da região de interesse nas imagens de face foi realizada usando o Algoritmo de Viola-Jones, enquanto que para segmentar e localizar a íris foi utilizado o algoritmo de Wildes e Camus. Ao final deste processo, ambas as imagens de íris e face resultantes foram reescaladas para  $128 \times 128$  pixels.

Após a extração das regiões de interesse das imagens, foi aplicada a transformada Wavelet usando 3 níveis de decomposição, sendo que as sub-imagens  $LL_3$ ,  $LH_3$ ,  $HL_3$  e  $HH_3$  foram utilizadas para compor o vetor de característica. As Funções Wavelet e a quantidade de coeficientes gerados por cada uma delas são exibidos na Tabela II.

TABELA II. QUANTIDADE DE COEFICIENTES GERADOS POR CADA FUNÇÃO WAVELET.

Função Wavelet	Quantidade de Coeficientes
Daubechies 2 (DB 2)	1296
Daubechies 4 (DB 4)	1936
Symlet 3 (SYM 3)	1600
Symlet 4 (SYM 4)	1936
Symlet 5 (SYM 5)	2116

Em relação ao classificador OPF, a Tabela I apresenta as métricas de distância utilizadas. De forma a avaliar o desempenho do classificador, foi utilizada a estratégia de validação cruzada com 10 folds, sendo que nessa estratégia o conjunto de dados é dividido em 10 diferentes partes com o mesmo tamanho, onde 1 parte é utilizada para testar o sistema, enquanto as restantes são utilizadas para treinamento. Esse processo é repetido 10 vezes, sempre selecionando uma parte que ainda não foi utilizada para teste, garantindo que todas as partes sejam testadas uma única vez.

### C. Resultados obtidos com os Sistemas Unimodais

Nessa seção são apresentados os resultados alcançados com o classificador OPF usando as diferentes métricas de distância e diferentes funções Wavelets para a construção dos vetores de características obtidos da face e íris. Os resultados descritos na Tabela III representam o desempenho médio dos sistemas unimodais, em termos de taxa de reconhecimento e desvio padrão obtido na validação cruzada com 10 folds.

TABELA III. RESULTADOS OBTIDOS COM OS SISTEMAS BIOMÉTRICOS UNIMODAIS USANDO FACE OU ÍRIS.

Wavelet	Distância	Taxa de Acerto	
		Face	Íris
DB 2	Euclidiana	87,72%±0,93%	84,43%±2,21%
	Manhattan	<b>90,61%±0,76%</b>	<b>92,24%±1,91%</b>
	Chi-Quadrada	73,17%±1,14%	75,48%±1,33%
DB 4	Euclidiana	86,67%±0,96%	84,71%±1,86%
	Manhattan	<b>89,49%±0,73%</b>	<b>91,48%±2,34%</b>
	Chi-Quadrada	69,60%±0,46%	71,57%±1,42%
SYM 3	Euclidiana	87,09%±0,85%	83,76%±1,75%
	Manhattan	<b>90,30%±0,94%</b>	<b>92,05%±2,20%</b>
	Chi-Quadrada	70,72%±0,77%	71,29%±1,88%
SYM 4	Euclidiana	87,12%±0,95%	83,95%±1,40%
	Manhattan	<b>90,50%±0,92%</b>	<b>91,81%±2,15%</b>
	Chi-Quadrada	69,49%±0,55%	71,95%±2,17%
SYM 5	Euclidiana	86,82%±1,03%	84,57%±1,71%
	Manhattan	<b>89,99%±0,88%</b>	<b>91,24%±1,70%</b>
	Chi-Quadrada	68,48%±0,96%	71,90%±2,47%

Os sistemas biométricos baseados em face forneceram desempenho satisfatório, sendo que foi obtida uma taxa de reconhecimento superior a 90% para algumas funções Wavelet. Em relação às métricas de distância utilizadas, pode-se verificar que a distância de Manhattan forneceu os melhores resultados, independente do tipo de função Wavelet utilizada, enquanto que a distância Chi-Quadrada forneceu os piores resultados. Neste caso, foram obtidas taxas de reconhecimento menores que 74%.

O melhor resultado envolvendo face foi alcançado usando a função Wavelet Daubechies de ordem 2 e distância de Manhattan, neste caso foi obtida uma taxa de acerto de 90,61% ± 0,76%. Resultados similares foram alcançados usando outros tipos de função Wavelet. Considerando o melhor cenário para a distância Euclidiana foi alcançada uma taxa de acerto igual a 87,72%±0,93% e para a distância Chi-Quadrada foi obtido uma taxa de acerto de 73,17%±1,14%, sendo que ambos os resultados foram alcançados usando a função Wavelet Daubechies de ordem 2.

Nos sistemas baseados em íris pode-se verificar que, similar aos sistemas envolvendo face, os melhores desempenho foram obtidos com a distância de Manhattan, onde o melhor desempenho global foi obtido com a função Wavelet Daubechies de ordem 2 com taxa de acerto igual a 92,24%±1,91%. Novamente, a distância Chi-Quadrada produziu os piores resultados, sendo que no melhor cenário foi obtido taxa de acerto igual a 75,48% ± 1,33% usando a função Wavelet Daubechies 2. Para a distância Euclidiana o melhor resultado foi obtido usando função Wavelet Daubechies de ordem 4 com uma taxa de acerto igual a 84,71% ± 1,86%.

Em relação aos sistemas unimodais baseado em face ou íris pode-se observar que o desempenho alcançado foi satisfatório, sendo que no melhor caso foi obtido taxa de acerto superior a 90% de acerto para ambas as modalidades biométricas. Além disso, vale destacar que a distância de

Manhattan foi capaz de gerar os melhores desempenhos, enquanto que a distância Chi-Quadrada forneceu os piores resultados.

### D. Resultados obtidos com os Sistemas Multimodais

Esta seção descreve os resultados obtidos para os sistemas biométricos multimodais usando as estratégias de combinação descritas na Seção III e o classificador OPF com as métricas de distância descrita na Tabela II. Os resultados apresentados na Tabela IV representam o desempenho médio e o desvio padrão obtido na validação cruzada com 10 folds.

Em relação às estratégias de combinação pode-se verificar que a maioria dos resultados (destacados em negrito na Tabela IV), em termos de taxa de reconhecimento, ficaram ligeiramente superiores aos obtidos com os sistemas biométricos baseados em face. Isto mostra que os sistemas multimodais apresentaram desempenho com taxa de reconhecimento bastante satisfatória. No entanto, comparando os resultados alcançados pelos sistemas multimodais com aqueles obtidos pelos sistemas biométricos baseados em íris, pode-se observar que apenas as estratégias #3 e #8 conseguiram superar o desempenho desses. A Estratégia #8 com distância de Manhattan, independente da função Wavelet, produziu os melhores resultados. Neste caso, o melhor resultado global foi de 96,62% ± 1,01% com a função Wavelet Daubechies de ordem 2.

Um ponto interessante é que a distância Chi-Quadrada para as estratégias de fusão #1, #3 ou #4 nos sistemas multimodais pode fornecer alto grau de reconhecimento. Vale lembrar que esta métrica nos sistemas unimodais produziu os piores resultados. Usando esta métrica com a função Wavelet Symlet de ordem 4 e estratégia de fusão #3 superou o melhor desempenho obtido com a íris, alcançando uma taxa de reconhecimento igual a 92,71% ± 0,63%.

Os sistemas biométricos multimodais usando distância Euclidiana, para a maioria das estratégias de fusão, conseguiram fornecer desempenho superior quando comparado aos sistemas unimodais, independente da modalidade biometria, para a mesma métrica de distância.

De forma geral pode-se verificar que os sistemas biométricos multimodais conseguem fornecer uma taxa de reconhecimento superior, desde que a estratégia de combinação, métrica de distância e a função Wavelet sejam escolhidas adequadamente. No melhor cenário foi possível obter uma melhora no desempenho em torno de 5%.

## VII. CONCLUSÃO

Neste trabalho, foi realizada uma avaliação sistemática do classificador OPF para reconhecimento biométrico unimodal e multimodal, usando as modalidades biométrica face e íris e a transformada Wavelet para extração de características. Os resultados demonstraram que o OPF é capaz de produzir taxas de reconhecimento superiores à 90%.

No caso dos sistemas biométricos multimodais, a métrica de distância e a estratégia de combinação das modalidades biométricas são fatores importantes e devem receber atenção especial durante o projeto de tais sistemas. A distância de

TABELA IV. RESULTADOS OBTIDOS COM AS ESTRATÉGIAS DE COMBINAÇÃO PARA AS MODALIDADES BIOMÉTRICAS FACE E ÍRIS.

Wavelet	Distância	Taxa de Acerto							
		Estratégia 1	Estratégia 2	Estratégia 3	Estratégia 4	Estratégia 5	Estratégia 6	Estratégia 7	Estratégia 8
DB 2	Euclidiana	89,56%±0,52%	87,33%±0,57%	89,65%±0,65%	87,51%±0,91%	87,73%±0,95%	87,73%±0,95%	87,45%±0,90%	90,32%±0,99%
	Manhattan	88,44%±0,64%	<b>91,15%±0,63%</b>	89,83%±0,79%	90,62%±0,80%	<b>90,58%±0,78%</b>	<b>90,61%±0,77%</b>	<b>91,20%±0,91%</b>	<b>96,62%±1,01%</b>
	Chi-Quadrada	<b>90,49%±0,62%</b>	70,62%±1,14%	<b>91,27%±0,87%</b>	<b>91,20%±0,73%</b>	73,38%±0,96%	73,22%±1,25%	73,39%±0,99%	77,08%±2,12%
DB 4	Euclidiana	89,63%±0,73%	86,37%±0,92%	90,04%±0,71%	87,53%±0,63%	86,66%±0,94%	86,66%±0,95%	86,13%±0,81%	88,92%±1,75%
	Manhattan	88,10%±0,77%	<b>90,13%±0,72%</b>	89,74%±0,83%	89,75%±0,77%	<b>89,49%±0,73%</b>	<b>89,49%±0,70%</b>	<b>89,50%±0,72%</b>	<b>95,74%±1,18%</b>
	Chi-Quadrada	<b>90,26%±0,89%</b>	68,06%±0,83%	<b>91,74%±0,65%</b>	<b>90,72%±0,78%</b>	69,75%±0,78%	69,67%±0,84%	69,80%±1,04%	71,96%±1,85%
SYM 3	Euclidiana	89,66%±0,60%	86,97%±1,16%	89,93%±0,70%	87,95%±0,83%	87,09%±0,86%	87,08%±0,87%	86,55%±0,88%	88,73%±1,15%
	Manhattan	88,34%±0,63%	<b>90,66%±0,67%</b>	89,97%±0,78%	90,16%±0,71%	<b>90,29%±0,94%</b>	<b>90,29%±0,95%</b>	<b>90,34%±0,71%</b>	<b>95,70%±1,03%</b>
	Chi-Quadrada	<b>90,09%±0,59%</b>	68,68%±0,79%	<b>91,90%±0,75%</b>	<b>91,19%±0,66%</b>	71,06%±0,64%	71,02%±0,73%	71,09%±0,92%	72,35%±2,76%
SYM 4	Euclidiana	90,75%±0,63%	86,67%±1,31%	90,92%±0,48%	86,95%±1,10%	87,10%±0,93%	87,12%±0,93%	86,85%±0,89%	88,22%±1,52%
	Manhattan	89,75%±0,88%	<b>90,75%±0,77%</b>	90,91%±0,72%	89,89%±0,80%	<b>90,49%±0,94%</b>	<b>90,50%±0,97%</b>	<b>90,57%±0,76%</b>	<b>95,90%±1,10%</b>
	Chi-Quadrada	<b>91,29%±0,62%</b>	67,99%±0,90%	<b>92,71%±0,63%</b>	<b>91,07%±0,68%</b>	69,25%±0,58%	69,41%±0,68%	70,39%±0,53%	72,53%±1,95%
SYM 5	Euclidiana	90,41%±0,80%	86,73%±1,02%	90,83%±0,55%	87,60%±0,86%	86,82%±1,03%	86,80%±1,06%	86,55%±0,92%	88,51%±1,36%
	Manhattan	89,28%±0,95%	<b>90,47%±0,78%</b>	90,53%±0,63%	90,15%±0,80%	<b>89,99%±0,91%</b>	<b>89,98%±0,93%</b>	<b>90,49%±0,95%</b>	<b>95,70%±1,13%</b>
	Chi-Quadrada	<b>90,69%±0,83%</b>	67,90%±0,67%	<b>92,05%±0,87%</b>	<b>90,96%±0,63%</b>	68,65%±0,78%	68,34%±0,89%	69,33%±0,97%	71,39%±2,04%

Manhattan, independente do tipo de sistema biométrico e da modalidade biométrica, foi capaz de produzir resultados superiores a outras métricas de distâncias.

Por outro lado, verifica-se que o desempenho dos sistemas biométricos unimodais ou multimodais não são sensíveis à escolha das funções Wavelets utilizadas para extração de característica, ou seja, todas as funções Wavelets utilizadas produziram características bastante discriminativas. Os melhores resultados foram alcançados usando a função Wavelet Daubechies 2.

Como trabalhos futuros, serão realizados novos experimentos utilizando outras modalidades biométricas, tais como EEG, ECG e impressão digital, além do emprego de novas estratégias de extração de características e outros classificadores tais como Máquinas de Vetores Suporte.

#### AGRADECIMENTO

Nós gostaríamos de agradecer ao Grupo MLA da Shandong University pela base de dados SDUMLA-HMT (We would like to express our thanks to the MLA Group of Shandong University for the SDUMLA-HMT Database). O primeiro e último autor agradecem a CAPES e ao CNPq (processo # 304603/2012-0) pelo auxílio financeiro.

#### REFERÊNCIAS

[1] A. K. Jain, P. Flynn, and A. A. Ross, *Handbook of Biometrics*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2007.

[2] D. M. Rankin, B. W. Scotney, P. J. Morrow, and B. K. Pierscionek, "Iris recognition failure over time: The effects of texture," *Pattern Recogn.*, vol. 45, no. 1, pp. 145–150, Jan. 2012.

[3] K. Cao, X. Yang, X. Chen, Y. Zang, J. Liang, and J. Tian, "A novel ant colony optimization algorithm for large-distorted fingerprint matching," *Pattern Recognition*, vol. 45, no. 1, pp. 151 – 161, 2012.

[4] H. Zhang, N. M. Nasrabadi, Y. Zhang, and T. S. Huang, "Joint dynamic sparse representation for multi-view face recognition," *Pattern Recogn.*, vol. 45, no. 4, pp. 1290–1298, Apr. 2012.

[5] A. Jain, A. Ross, and S. Prabhakar, "An introduction to biometric recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 4–20, 2004.

[6] V. M. Mane and D. V. Jadhav, "Review of multimodal biometrics: Applications, challenges and research areas," *International Journal of Biometrics and Bioinformatics (IJBB)*, 2009.

[7] A. Ross and A. K. Jain, "Multimodal Biometrics: an overview," 2004, pp. 1221–1224.

[8] S. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674–693, Jul 1989.

[9] J. P. Papa, A. X. Falcão, and C. T. N. Suzuki, "Supervised pattern classification based on optimum-path forest," *International Journal Imaging Systems Technologies*, vol. 19, no. 2, pp. 120–131, Jun. 2009. [Online]. Available: <http://dx.doi.org/10.1002/ima.v19:2>

[10] T. M. Nunes, A. L. Coelho, C. A. Lima, J. P. Papa, and V. H. C. de Albuquerque, "{EEG} signal classification for epilepsy diagnosis via optimum path forest : A systematic assessment," *Neurocomputing*, vol. 136, no. 0, pp. 103 – 123, 2014.

[11] L. Afonso, J. Papa, A. Marana, A. Poursaberi, and S. Yanushkevich, "A fast large scale iris database classification with optimum-path forest technique: A case study," in *The 2012 International Joint Conference on Neural Networks (IJCNN)*, June 2012, pp. 1–5.

[12] Y. Yin, L. Liu, and X. Sun, "SDUMLA-HMT: A multimodal biometric database," in *Biometric Recognition*, ser. Lecture Notes in Computer Science, Z. Sun, J. Lai, X. Chen, and T. Tan, Eds. Springer Berlin Heidelberg, 2011, vol. 7098, pp. 260–268.

[13] P. Viola and M. Jones, "Robust real-time face detection," *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, 2004.

[14] T. Camus and R. Wildes, "Reliable and fast eye finding in close-up images," in *Proceedings of the 16th International Conference on Pattern Recognition, 2002*, vol. 1, 2002, pp. 389–394 vol.1.

[15] J. Daugman, "How iris recognition works," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, pp. 21–30, 2002.

[16] D. M. M. da Costa, H. Passos, S. Peres, and C. Lima, "Um estudo comparativo das estratégias de fusão no nível de característica para sistemas biométricos multimodais baseados em face e íris," in *SBSI 2015: Main Track*, Goiânia-GO, Brazil, may 2015.

[17] V. Divyaloshini and M. Saraswathi, "Performance evaluation of image fusion techniques and its implementation in biometric recognition," *International Journal of Technology Enhancements and Emerging Engineering Research*, vol. 2, no. 3, 2014.

[18] Z. Wang, Q. Han, X. Niu, and C. Busch, "Feature-level fusion of iris and face for personal identification," in *Advances in Neural Networks*, ser. Lecture Notes in Computer Science, W. Yu, H. He, and N. Zhang, Eds. Springer Berlin Heidelberg, 2009, vol. 5553, pp. 356–364.

[19] A. Khare, R. Srivastava, and R. Singh, "Edge preserving image fusion based on contourlet transform," in *Proceedings of the 5th International Conference on Image and Signal Processing*, ser. ICISP'12. Berlin, Heidelberg: Springer-Verlag, 2012, pp. 93–102.

[20] A. Ross and R. Govindarajan, "Feature level fusion using hand and face biometrics," in *Proc. SPIE*, 2005, pp. 196–204.

[21] S. Mallat, *A Wavelet Tour of Signal Processing: The Sparse Way*, 3rd ed. Academic Press, 2008, ch. 7, pp. 410–418.