

Sistema de Detecção de Pontos Fiduciais utilizando Classificadores Lineares C-SVC

Luiz Eduardo Sales e Silva, Kenny Vinente dos Santos, Waldir Sabino da Silva Júnior

Resumo—Atualmente, há um crescente interesse da comunidade científica e/ou industrial em relação a métodos que oferecem soluções para o problema da detecção de pontos fiduciais em faces humanas. Alguns métodos empregam o SVM para classificação, porém observamos que algumas formulações dos problemas de otimização não foram abordadas. Neste artigo, propomos investigar o desempenho da formulação matemática C-SVC, quando empregada em um classificador de um sistema de detecção de pontos fiduciais em faces humanas. Um aspecto importante desta pesquisa é explorar parâmetros que não foram utilizados na literatura, para treinamento do SVM. Em termos de comparações, os resultados demonstram que o método proposto possui desempenho competitivo sendo que, em alguns casos, o método proposto supera o desempenho dos demais.

Palavras-Chave—SVM, detecção de padrões, pontos fiduciais.

Abstract—Currently, there is a growing interest from the scientific and/or industrial community in respect to methods that offer solutions to the problem of fiducial points detection of human faces. Some methods use the SVM for classification, but we observed that some formulations of optimization problems were not discussed. In this article, we propose to investigate the performance of mathematical formulation C-SVC when employed in a classifier for fiducial points detection system of human faces. An important aspect this research is to explore the parameters that have not been used in the literature for training the SVM. In terms of comparison, the results demonstrate that the proposed method has competitive performance and, in some cases, the proposed method outperforms others.

Keywords—SVM, pattern detection, fiducial points.

I. INTRODUÇÃO

Atualmente, há um crescente interesse da comunidade científica e/ou industrial em relação a métodos que ofereçam soluções para o problema da detecção de pontos fiduciais (pontos salientes [1], por exemplo, ponta do nariz) em faces humanas [1], [2] e [3]. Esta convergência de esforços de pesquisadores e desenvolvedores deve-se principalmente à natureza do problema, envolvendo uma ampla variação dos padrões [4], e da potencial comercialização dos métodos desenvolvidos. Por exemplo, os métodos podem ser embutidos

L. E. Sales e Silva e K. V. dos Santos são mestrandos do Programa de Pós-graduação em Engenharia Elétrica e pesquisadores do Centro de Pesquisa e Desenvolvimento em Tecnologia Eletrônica e da Informação, PPGEE e CETELI, Universidade Federal do Amazonas, UFAM, Av. Gen. Rodrigo Octávio Jordão Ramos, 3000, Manaus - AM, 69077-000, Brasil. (e-mail: luiz.edu.sales@gmail.com; kennyvinente@gmail.com). Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

W. S. da Silva Júnior é professor do Departamento de Eletrônica e Computação, Programa de Pós-graduação em Engenharia Elétrica e pesquisador do Centro de Pesquisa e Desenvolvimento em Tecnologia Eletrônica e da Informação, DTEC, PPGEE e CETELI, Universidade Federal do Amazonas, UFAM, Av. Gen. Rodrigo Octávio Jordão Ramos, 3000, Manaus - AM, 69077-000, Brasil. (e-mail: waldirjr@ufam.edu.br).

em dispositivos eletrônicos como *smartphones* [5] e televisores [6].

Normalmente, os autores categorizam os métodos de detecção de pontos fiduciais de duas formas: local e global [2]. Em métodos locais, a principal característica reside no fato de que os pontos fiduciais são tratados e detectados de maneira individual, ou seja, informações complementares ao ponto fiducial não são utilizadas (por exemplo, os detectores são projetados somente para o canto esquerdo da boca). Os métodos globais são caracterizados por detectar os pontos fiduciais de modo conjunto utilizando modelos deformáveis, sendo menos suscetíveis à variação de pose e iluminação em relação aos locais.

O projeto do classificador constitui uma das etapas mais importantes de um sistema (supervisionado) para detecção de pontos fiduciais. Nesta etapa, diversas técnicas de aprendizado de máquina podem ser utilizadas [1], [2], [3] e [7]. Em particular, algumas abordagens [8] empregam o método denominado por Máquina de Vetores Suporte (SVM) [9] para classificação. A formulação matemática do SVM é obtida através de um problema de otimização com restrições [10]. Um aspecto crucial é que podemos formular este problema de otimização com diferentes parâmetros e ligeiras modificações nas restrições. Dessa forma, para cada formulação, temos um conjunto de parâmetros associados que precisam ser escolhidos no treinamento [11], o que afeta diretamente o desempenho do classificador.

Neste artigo, propomos investigar o desempenho da formulação matemática do SVM denominada C-SVC [10], quando empregada em um classificador de um sistema de detecção de pontos fiduciais em faces humanas. Um aspecto importante desta pesquisa é explorar parâmetros que não foram utilizados na literatura, para treinamento do SVM. Para avaliação de desempenho, empregamos o classificador projetado, através do método C-SVC, em um sistema de detecção de pontos fiduciais. O treinamento do algoritmo foi realizado utilizando-se seis (06) pontos fiduciais simétricos da face, de uma base de dados composta por 503 imagens (subconjunto da base *BioID* [12]). Para comparação, o desempenho do sistema com classificador C-SVC foi confrontado com os de métodos similares. Especificamente, utilizamos 3 outros sistemas, 2 que utilizam o método por filtragem discriminativa e 1 que utiliza o SVM linear [3]. Os resultados demonstram que o método proposto possui desempenho competitivo, sendo que, em alguns casos, o método proposto supera o desempenho dos demais.

O restante do artigo está organizado da seguinte forma. Na próxima seção é feita uma revisão da literatura acerca dos trabalhos relacionados. Na Seção III, é apresentada uma breve descrição do SVM. O sistema proposto é mostrado na Seção IV, na qual é enfatizado o projeto dos classificadores,

parâmetros de otimização dos diferentes tipos de SVM e os parâmetros escolhidos, além de serem apresentadas as etapas de treinamento e testes, resultados obtidos e são feitos comentários sobre esses resultados. Por fim, o artigo é concluído na Seção V.

II. TRABALHOS RELACIONADOS

Podemos encontrar na literatura diversos métodos que oferecem soluções, públicas ou privadas, para o problema da detecção de pontos fiduciais [3], [7], [13], [14], [15] e [16]. Nesta seção, apresentamos uma breve revisão da literatura com respeito aos métodos recentes que proporcionam a detecção de pontos fiduciais bem como alguns sistemas de reconhecimento de faces que utilizam subsistemas para detecção de pontos fiduciais.

Em [7], os autores empregam um *framework* para o reconhecimento de faces que utiliza um subsistema que detecta pontos fiduciais. A detecção destes pontos combina duas técnicas. A primeira usa os coeficientes dos filtros de *Gabor* para detecção local dos pontos e a segunda utiliza uma combinação de medidas antropométricas da face humana.

Em [14], os autores abordam o problema da detecção de pontos fiduciais de faces humanas utilizando classificadores SVM com *kernel* gaussiano. Neste, investigam-se dois parâmetros do classificador. O sistema proposto em [15] explora o mesmo problema. Neste, os autores utilizam classificadores projetados por filtros de correlação IPD (*Inner Product Detector*). Além disso, aplica-se o conceito de cascata para o projeto do classificador com o intuito de reduzir taxas de falsos positivos no treinamento. No trabalho [3], os autores utilizam filtros robustos para investigar o mesmo problema. Estes filtros são projetados utilizando-se as componentes principais. A robustez deve-se ao uso das componentes principais complementares para projeto dos filtros.

Em [13] e [16] foram desenvolvidos sistemas proprietários para detecção de pontos fiduciais. Esses sistemas são utilizados em aplicações para as áreas de vigilância, acesso às áreas restritas e identificação de pessoas em multidões.

III. MÁQUINA DE VETORES SUPORTE (SVM)

O método de aprendizado de máquina supervisionado denominado SVM, proposto por Vapnik [9], é utilizado amplamente para solução de problemas de classificação e regressão. O SVM foi desenvolvido visando a análise de dados baseada na programação quadrática convexa [17], inicialmente para solução de problemas que envolvam duas classes. No que diz respeito a separação de classes, o algoritmo SVM proporciona como saída um hiperplano de separação ótima. Na Figura 1, apresentamos um exemplo para separação de classes utilizando o hiperplano determinado pelo algoritmo SVM. A reta $\mathbf{w}^t \mathbf{x}_i + b = 0$ denomina-se por hiperplano de separação ótima. As retas $\mathbf{w}^t \mathbf{x}_i + b = \pm 1$ delimitam a margem de separação das classes.

Note que a margem de separação pode conter ou não elementos de classe. A margem suave é uma modificação do método para permitir o uso do classificador SVM quando as classes não são linearmente separáveis, o que torna o problema de otimização insolúvel para as margens rígidas. As variáveis de folga (*slack variables*) permitem que exista uma solução, como um compromisso entre a maximização da margem e




Fig. 1. Exemplo de separação entre duas classes utilizando SVM. O hiperplano de separação ótima (linha pontilhada) representa a região de decisão entre as duas classes. Os vetores suportes (linha sólida) estão a uma margem b do hiperplano. Cada vetor suporte é a solução da equação $\mathbf{w}^t \cdot \mathbf{x} + b = \pm 1$.

o erro de classificação, na qual o parâmetro C regula este compromisso. Dessa forma, utilizamos o conceito de margem suave apresentado para considerar a existência ou ausência de elementos de classe contidos na região delimitada pela margem de separação [10]. O emprego de margens suaves proporciona uma generalização do método SVM para lidar com problemas de separação de classes mais próximos da realidade. O uso das margens suaves implica na seguinte expressão:

$$y_i(\mathbf{w}^t \mathbf{x}_i + b) \geq 1 - \xi_i, \text{ para } i = \{1, \dots, n\}. \quad (1)$$

Na Equação (1), temos que: ξ_i , que assume valores ≥ 0 , é a variável de folga, y_i são os rótulos de classe, n representa o total de elementos de classe e o sobrescrito t representa o transposto do vetor. Para maximizar a margem de separação das classes e obtermos o hiperplano de separação ótima torna-se necessário encontrar a solução do problema de otimização definido por:

$$\begin{aligned} &\text{Minimizar} \quad \frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=1}^n \xi_i \right). \\ &\text{Restrito à} \quad y_i(\mathbf{w}^t \mathbf{x}_i + b) \geq 1 - \xi_i, \\ &\quad \text{para } i = \{1, \dots, n\}. \end{aligned} \quad (2)$$

Na Equação (2), C representa a ponderação imposta à margem suave. A implementação deste problema de otimização é conhecida por C-SVC [10]. Podemos encontrar na literatura várias implementações do algoritmo SVM. Estas implementações diferem-se entre vários aspectos: na formulação da Equação (1), na função de otimização utilizada e ainda os parâmetros utilizados para variação. Algumas destas implementações estão apresentadas na Tabela I. Observamos que o desempenho de cada algoritmo também depende da escolha adequada dos parâmetros, o que justifica a procura pelo melhor conjunto de parâmetros do SVM.

IV. SISTEMA DE DETECÇÃO DE PONTOS FIDUCIAIS UTILIZANDO CLASSIFICADORES C-SVC

A. Projeto dos Classificadores C-SVC

Conforme comentado na Seção III, podemos encontrar diversas formulações para o problema de otimização do método SVM. Em nossa pesquisa, empregamos o problema de otimização denominado C-SVC para projeto do classificador de um sistema de detecção de pontos fiduciais. Um dos aspectos cruciais (veja Seção III) consiste em definir exatamente quais são os parâmetros utilizados e quais são os

TABELA I
PROBLEMAS DE OTIMIZAÇÃO E RESTRIÇÕES DO MÉTODO SVM.

Formulação	Problema de Otimização	Parâmetros
C-SVC	Minimizar: $\frac{1}{2} \ \mathbf{w}\ ^2 + C \left(\sum_{i=1}^n \xi_i \right)$ Restrito à: $y_i(\mathbf{w}^t \mathbf{x}_i + b) \geq 1 - \xi_i$, para: $\xi_i \geq 0$ e $i = \{1, \dots, n\}$.	C
ν -SVC	Minimizar: $\frac{1}{2} \ \mathbf{w}\ ^2 - \nu \rho + \frac{1}{n} \left(\sum_{i=1}^n \xi_i \right)$ Restrito à: $y_i(\mathbf{w}^t \mathbf{x}_i + b) \geq \rho - \xi_i$, para: $\xi_i \geq 0$ e $i = \{1, \dots, n\}$.	ν, ρ
One Class	Minimizar: $\frac{1}{2} \ \mathbf{w}\ ^2 - \rho + \frac{1}{\nu \cdot n} \left(\sum_{i=1}^n \xi_i \right)$ Restrito à: $\mathbf{w}^t \mathbf{x}_i \geq \rho - \xi_i$, para: $\xi_i \geq 0$ e $i = \{1, \dots, n\}$.	ν, ρ
ϵ -SVR	Minimizar: $\frac{1}{2} \ \mathbf{w}\ ^2 + C \left(\sum_{i=1}^n \xi_i \right) + C \left(\sum_{i=1}^n \xi_i^* \right)$ Restrito à: $\mathbf{w}^t \mathbf{x}_i + b - z_i \geq \epsilon + \xi_i$, $z_i - \mathbf{w}^t \mathbf{x}_i - b \geq \epsilon + \xi_i^*$, para: $\xi_i, \xi_i^* \geq 0$ e $i = \{1, \dots, n\}$.	C, ϵ
ν -SVR	Minimizar: $\frac{1}{2} \ \mathbf{w}\ ^2 + C \left(\nu \epsilon + \frac{1}{n} \sum_{i=1}^n (\xi_i + \xi_i^*) \right)$ Restrito à: $\mathbf{w}^t \mathbf{x}_i + b - z_i \geq \epsilon + \xi_i$, $z_i - \mathbf{w}^t \mathbf{x}_i - b \geq \epsilon + \xi_i^*$, para: $\xi_i, \xi_i^* \geq 0$ e $i = \{1, \dots, n\}$.	C, ν, ϵ

seus intervalos numéricos. Especificamente em nossa pesquisa, exploramos os parâmetros a seguir:

- Parâmetro de regularização C com valores iguais à 2^n com $n = \{-12, -11, \dots, 8\}$;
- Variáveis de folga ξ_i (veja Tabela I) com valores iguais à 0,001; 0,01; 0,1.
- Número máximo de iterações para convergência: 10000; 18000; 26000; 34000; 42000; 50000.
- Ponderação da quantidade de elementos de classe em proporção na ordem (positivos:negativos): (1:1), (1:5), (2:10), (10:500), (5:1), (10:2) e (500:10).

As faixas de variações investigadas dos parâmetros foram obtidas de maneira empírica através de resultados preliminares. Verificamos que estas faixas influenciavam sensivelmente o desempenho do sistema de detecção de pontos fiduciais. Um aspecto importante é observar que cada um dos parâmetros e suas faixas de variações representam um experimento que deve ser explorado. Esta abordagem denomina-se *grid* de parâmetros [10]. Em nossa pesquisa, temos um extenso *grid* de parâmetros formado por 756 combinações.

B. Sistema de Detecção de Pontos Fiduciais utilizando Classificadores C-SVC

O sistema de detecção de pontos fiduciais possui duas etapas distintas: treinamento e teste. Primeiramente, todas as imagens são pré-processadas utilizando-se um procedimento comum tanto na etapa de treinamento quanto na de teste. O diagrama em blocos para pré-processamento é apresentado na Figura 2. O primeiro bloco consiste em um enquadramento da face da imagem de entrada utilizando um detector de faces humanas Viola-Jones [18], a seguir realizamos um escalonamento da imagem para uma resolução igual a 220×220 e por fim, realizamos a correção de iluminação [19].

Na etapa de treinamento do sistema (observe a Figura 3), primeiramente, a imagem é pré-processada conforme descrição no parágrafo anterior. A seguir, utilizamos uma técnica para selecionar uma região elíptica de interesse com alta probabilidade de conter o ponto fiducial. Esta região é obtida da




Fig. 2. Diagrama em blocos para pré-processamento das imagens (treinamento e teste). Em particular, apresentamos uma imagem sendo pré-processada. As imagens, conectadas aos blocos, expressam uma visualização da saída.

seguinte maneira: considere uma função densidade de probabilidade gaussiana com média $\mu_{\mathcal{X}}$ e matriz de covariância $\Sigma_{\mathcal{X}}$, onde $\mathcal{X}$ é uma variável aleatória com N realizações iguais às coordenadas dos pontos fiduciais $\mathbf{x}_i = (x_{1i}, x_{2i})$ das imagens de treinamento (com $i = \{1, \dots, N\}$). A distância euclidiana máxima, acrescida em 5%, entre $\mu_{\mathcal{X}}$ e todos os $\mathbf{x}_i$ definirá a região elíptica de interesse. Assim, um candidato a ponto fiducial com coordenadas $\mathbf{y} = (y_1, y_2)$, somente será considerado caso:

$$\max\{1, 0.5|\mathbf{x}_i - \mu_{\mathcal{X}}|^2\} \geq (\mathbf{y} - \mu_{\mathcal{X}})^t \Sigma_{\mathcal{X}}^{-1} (\mathbf{y} - \mu_{\mathcal{X}}), \quad (3)$$

observe que a Equação (3), pode ser interpretada se visualizarmos a região elíptica de interesse na saída do bloco *Modelo Gaussiano à Priori* (Figura 3). A seguir, realizamos a seleção dos blocos $B_{\mathbf{z}}$, com dimensões 13×13 , para definição das classes de positivos (bloco cujo centro é o ponto fiducial) e de negativos (outros blocos da imagem), onde $\mathbf{z}$ representa as coordenadas do centro do bloco. Devido ao elevado número de negativos, selecionamos uma quantidade limitada de blocos que é feita utilizando-se um algoritmo de geração de coordenadas bidimensionais aleatórias denominado *Salt and Pepper* [20]. A proporção entre negativos e positivos é de 160/1. O processamento dos blocos segue com a transformação de cada bloco $B_{\mathbf{z}}$ (matriz) em um vetor $v(B_{\mathbf{z}})$ através da concatenação das linhas transpostas da matriz. Por fim, utilizamos os blocos

das classes de positivos e negativos para projetar o classificador C-SVC utilizando todas as especificações apresentadas na Seção IV-A.




Fig. 3. Diagrama em blocos para treino do sistema de detecção de pontos fiduciais utilizando classificadores C-SVC.

O diagrama em blocos do sistema para teste, apresentado na Figura 4, pode ser descrito como segue: primeiramente, assim como no treinamento, aplicamos o pré-processamento nas imagens. A seguir, delimitamos a região elíptica de interesse utilizando os valores, determinados no treinamento, da média $\mu_{\mathcal{X}}$ e da matriz de covariância $\Sigma_{\mathcal{X}}$ da função densidade de probabilidade gaussiana. Após, cada bloco B_z é processado utilizando-se uma janela deslizante. O vetor $v(B_z)$ é obtido através da transformação da matriz B_z em um vetor (de forma idêntica à transformação realizada no treinamento). Por último, utilizamos o classificador C-SVC, determinado no treinamento, para categorizar o vetor $v(B_z)$ na classe de positivos ou na de negativos.




Fig. 4. Diagrama em blocos para teste do sistema de detecção de pontos fiduciais utilizando classificadores C-SVC.

C. Experimentos

O projeto do classificador C-SVC e todas as etapas de treinamento e teste do sistema de detecção de pontos fiduciais, descritos nas Seções IV-A e IV-B, foram implementadas utilizando-se a biblioteca em C++ denominada *OpenCV* (*Open Source Computer Vision Library*) [21]. Esta biblioteca possui funções matemáticas e métodos específicos, por exemplo, das áreas de processamento de sinais e aprendizado de máquina.

Em nossos experimentos, utilizamos 06 pontos fiduciais simétricos da face conforme apresentado na Figura 5. Para cada ponto fiducial, utilizamos o sistema descrito na Seção IV-B, ou seja, temos 06 sistemas de detecção distintos. Em todos os experimentos, utilizamos validação cruzada [22] com 7 partições (valor comumente encontrado na literatura [23]), ou seja, em cada experimento temos dois conjuntos diferentes para treino e para teste. No conjunto de treinamento utilizamos

6/7 do total de imagens da base de dados para treinamento e verificação de parâmetros e no conjunto de teste utilizamos 1/7 do total de imagens para validar o desempenho do algoritmo.




Fig. 5. Pontos fiduciais com simetria e uma face humana considerados nos experimentos.

Os experimentos foram executados utilizando-se um cluster de computadores com 30 núcleos, cada um com memória RAM de 4GB e processador 2,26GHz. Em nossos experimentos utilizamos um subconjunto formado por 503 imagens da base de dados *BioID* [12]. Em uma breve descrição, a base completa é composta por 1521 imagens em níveis de cinza de 23 indivíduos, a resolução das imagens é de 384×286 pixels. As faces possuem variações de escala, iluminação e pequenas rotações. Considerando todos os parâmetros para projeto do classificador C-SVC e os 06 pontos fiduciais simétricos da face foram realizados um total de 4536 experimentos.

D. Resultados

O desempenho do classificador é medido utilizando-se uma métrica normalizada pela distância entre as coordenadas manuais (fornecida pela base de dados) dos centros dos olhos esquerdo e direito. Esta distância, denominada $\tilde{d}_o$, é obtida da seguinte forma:

$$\tilde{d}_o = \|\widetilde{\mathbf{OE}} - \widetilde{\mathbf{OD}}\|,$$

onde: $\widetilde{\mathbf{OE}}$ corresponde às coordenadas do rótulo manual do centro do olho esquerdo e $\widetilde{\mathbf{OD}}$ são as coordenadas do rótulo manual do centro do olho direito. Supondo um candidato $\mathbf{x}$ e as coordenadas manuais do ponto fiducial igual a $\mathbf{PF}$ então define-se $d_{\mathbf{PF}}$ como:

$$d_{\mathbf{PF}} = \|\mathbf{x} - \mathbf{PF}\| \quad (4)$$

O desempenho do classificador é medido através das taxas de Verdadeiros Positivos (TP) e Falsos Positivos (FP) conforme as expressões:

$$\text{TP} = 100 \frac{\text{Total de faces em que } d_{\mathbf{PF}} \leq 0,1 \tilde{d}_o}{\text{Total de faces}}, \quad (5)$$

$$\text{FP} = 100 \frac{\text{Total de candidatos a PF com } d_{\mathbf{PF}} > 0,1 \tilde{d}_o}{\text{Total de negativos}}. \quad (6)$$

Na Tabela II, apresentamos os resultados para 6 pontos fiduciais com simetria da face para o sistema proposto. Todos os resultados estão dispostos em termos das taxas de Verdadeiros Positivos (TP) e Falsos Positivos (FP) (segundo as Equações (5) e (6)). Para comparação de desempenho utilizamos os resultados dos métodos por filtragem discriminativa apresentados em [3] e de um sistema que utiliza classificador SVM com *kernel* linear. Podemos observar que os resultados das taxas de TP do método proposto superam os do método DF-PCA para os pontos fiduciais 0, 1 e 9. Em comparação com o sistema

TABELA II
DESEMPENHO DO SISTEMA PROPOSTO PARA 6 PONTOS FIDUCIAIS SIMÉTRICOS UTILIZANDO A BASE DE DADO *BioID*.

PF	DF-PCA				DF				SVM L				C-SVC (Proposto)			
	FP	σ	TP	σ	FP	σ	TP	σ	FP	σ	TP	σ	FP	σ	TP	σ
0	0,05	0,03	96,6	2,2	0,22	0,03	21,1	4,7	1,09	0,74	92,4	9,8	0,76	0,07	99,2	0,74
1	0,10	0,05	95,4	2,8	0,30	0,04	59,2	6,8	0,32	0,09	99,6	1,0	0,40	0,03	99,8	0,52
2	0,24	0,14	95,0	2,1	0,39	0,03	53,7	6,1	1,58	0,59	93,0	14,3	0,76	0,17	92,3	4,2
6	0,14	0,03	93,2	1,6	0,25	0,04	56,7	9,3	1,40	1,44	99,6	1,0	1,95	0,79	90,5	11,74
7	0,18	0,02	95,8	3,7	0,20	0,01	54,1	8,1	0,06	0,03	47,1	9,6	0,58	0,28	55,1	12,74
9	0,18	0,04	92,8	3,0	0,22	0,01	43,5	5,5	2,91	5,12	96,8	5,5	2,08	0,33	99,3	1,09

que utiliza classificadores SVM podemos verificar que as taxas de TP do sistema proposto são superiores, exceto no ponto fiducial 6. Visualmente, podemos verificar que as taxas de FP abaixo de 2% são consideradas satisfatórias. Este fato pode ser observado no método proposto, exceto no ponto fiducial 09. Por fim, podemos sintetizar que o sistema proposto apresenta bom desempenho.

V. CONCLUSÕES

Neste artigo, propomos explorar o desempenho da formulação matemática do SVM denominada C-SVC, quando empregada em um classificador de um sistema de detecção de pontos fiduciais de faces humanas. Nesta pesquisa, foram considerados parâmetros para o projeto do classificador C-SVC do sistema de detecção que não tinham sido explorados na literatura. O sistema supervisionado proposto completo foi implementado utilizando-se a biblioteca em C++ denominada *OpenCV*. Nesta pesquisa, considerando todos os parâmetros para projeto do sistema, temos que foram realizados um total de 4536 experimentos. O desempenho do sistema com classificadores C-SVC foi comparado com outros sistemas similares na literatura. Destes, 2 utilizam classificadores por filtragem discriminativa e 1 utiliza um classificador SVM linear. Avaliando o desempenho em termos de taxas de TP e FP podemos sintetizar que o sistema proposto apresenta bons resultados. Por fim, comentamos a importância da pesquisa de métodos que proporcionam a detecção de pontos fiduciais em faces humanas devido ao grande número de aplicações.

AGRADECIMENTOS

Agradecemos à Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

REFERÊNCIAS

- [1] Patil, R. A. and Sahula, V. and Mandal, A. S., "Automatic Detection of Facial Feature Points in Image Sequences". In: *Proceedings of the IEEE International Conference on Image Information Processing*, July, pp. 1-5, 2011.
- [2] B. Amberg and T. Vetter, "Optimal Landmark Detection using Shape Models and Branch and Bound". In: *Proceedings of the IEEE International Conference on Computer Vision*, October, pp. 455-462, 2011.
- [3] W. S. da Silva Júnior, G. M. Araújo, E. A. B. da Silva and S. K. Goldenstein, "Facial Fiducial Points Detection Using Discriminative Filtering on Principal Components". In: *Proceedings of the IEEE International Conference on Image Processing*, September, pp. 2681-2684, 2010.
- [4] Peter N. Belhumeur and David W. Jacobs and David J. Kriegman and Neeraj Kumar, "Localizing Parts of Faces Using a Consensus of Exemplars". In: *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*, October, pp. 545-552, 2011.
- [5] Chai, S., "Mobile Challenges for Embedded Computer Vision". *Advances in Pattern Recognition Embedded Computer Vision*, Springer, pp. 219-235, 2009.
- [6] "Samsung USA", [Último acesso em Abril de 2013] [Online]. Disponível em: <http://www.samsung.com/us/2013-smart-tv/>
- [7] S. Jahanbin, H. Choi and A.C. Bovik, "Passive Multimodal 2-D+3-D Face Recognition Using Gabor Features and Landmark Distances". *IEEE Transactions on Information Forensics and Security*, vol.6, pp. 1287-1304, 2011.
- [8] Du, Chunhua and Yang, Jie and Wu, Qiang and He, Xiangjian, "Locating Facial Landmarks by Support Vector Machine-based Active Shape Model". *International Journal of Intelligent Systems Technologies and Application*, vol. 10, n. 2, pp. 151-170, 2011.
- [9] V. N. Vapnik, *The Nature of Statistical Learning Theory*. New York, NY, USA: Springer-Verlag New York, Inc., 1998.
- [10] C. Chang and C. Lin, "LIBSVM: A Library for Support Vector Machines". *ACM Transactions on Intelligent Systems and Technology*, vol. 2, n. 3, 2011.
- [11] K. Wu and S. Wang "Choosing the Kernel Parameters for Support Vector Machines by the Inter-cluster in the Feature Space". *Journal on Pattern Recognition*, vol. 42, pp. 710-717, 2009.
- [12] "BioID Database", [Último acesso em Maio de 2013]. [Online]. Disponível em: <http://www.bioid.com/>
- [13] "Luxand", [Último acesso em Maio de 2013]. [Online]. Disponível em: <http://www.luxand.com/products/>
- [14] G. M. Araújo, W. S. da Silva Júnior, E. A. B. da Silva, and S. K. Goldenstein, "Detecção de Landmarks Faciais Usando SVM", In: *Anais do XXIX Simpósio Brasileiro de Telecomunicações*, pp. 1-5, Outubro, 2011.
- [15] G. M. Araújo, W. S. da Silva Júnior, E. A. B. da Silva, and S. K. Goldenstein, "Facial Landmarks Detection based on Correlation Filter", In: *Proceedings of the IEEE International Telecommunication Symposium*, Manaus, AM, Brazil, October 2010.
- [16] "Cognitec Systems", [Último acesso em Maio de 2013]. [Online]. Disponível em: <http://www.cognitec-systems.de/>
- [17] A. Pradhan, "Support Vector Machine - A Survey". *International Journal of Emerging technology and Advanced Engineering*, vol. 2, pp. 82-85, 2012.
- [18] Viola, P. and Jones, M., "Robust Real-Time Object Detection". *International Journal of Computer Vision*, vol. 57, n. 2, pp. 137-154, 2001.
- [19] Xiaoyang, T. and Triggs, B., Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions. *IEEE Transactions on Image Processing*, vol. 19, n. 6, pp. 1635-1650, 2010.
- [20] G. R., Arce, J. L., Paredes and J. Mullan, "Nonlinear Filtering for Image Analysis and Enhancement". In: A. L. Bovik (Ed.), *Handbook of Image & Video Processing*, Academic Press, 2000.
- [21] "Open Computer Vision Library - OpenCV", [Último acesso em Maio de 2013]. [Online]. Disponível em: <http://opencv.org/>
- [22] Reeves, S., "A Cross-Validation Framework for Solving Image Restoration Problems". *Journal of Visual Communication and Image Processing*, vol. 3, pp. 433-445, 1992.
- [23] Kohavi, R., "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection", In: *Proceedings of the International Joint Conference on Artificial Intelligence*, August, pp. 1137-1143, 1996.