

RECONHECIMENTO DE FACES COM IMAGENS INFRAVERMELHAS

Trabalho de Conclusão de Curso

Engenharia da Computação

Teógenes Eufrásio Bezerra
Orientador: Prof. Bruno José Torres Fernandes



UNIVERSIDADE
DE PERNAMBUCO

TEÓGENES EUFRÁSIO BEZERRA

**RECONHECIMENTO DE FACES COM
IMAGENS INFRAVERMELHAS**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia da Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, novembro de 2010.

(DEDICATÓRIA) Dedico este trabalho a minha mãe, Terezinha Bezerra dos Santos, que sempre depositou total confiança em minha capacidade e que sempre me orientou nas escolhas de sucesso na minha vida.

Agradecimentos

Agradeço a Deus e a meus pais, sem os quais eu jamais teria estudado nesta universidade, a meus colegas que curso, pelas batalhas que travamos juntos, aos meus familiares, pelo convívio afetivo e a minha esposa e meu filho pelo amor e carinho que me estimulam a alcançar novos objetivos.

Resumo

Reconhecimento facial é uma área de pesquisa em constante crescimento devido à alta demanda por segurança comercial. Quando se busca melhorar a qualidade da segurança os pesquisadores recorrem aos métodos biométricos. Desde o atentado de 11 de setembro os países de primeiro mundo investiram fortemente em aplicações de reconhecimento facial para captura de terroristas. Os sistemas de reconhecimento de face atuais chegaram ao nível de maturidade em que é possível obter sucesso no reconhecimento, mas não são tão eficientes sob variação de iluminação. Sistemas de reconhecimento facial que usam imagens infravermelhas são capazes de reconhecer faces em condições de iluminação diferentes ou sem controle de iluminação. Este trabalho apresenta um estudo comparativo para realização das etapas do reconhecimento de faces utilizando imagens infravermelhas. Ao final discutem-se as vantagens das técnicas utilizadas assim como uma comparação dos resultados alcançados.

Abstract

Facial recognition is a research area in constant growth due to high demand for commercial security. When it tries to improve the quality of security researchers to use biometric methods. Since the attacks of September 11 the first world countries have invested heavily in applications of facial recognition to capture terrorists. The face recognition systems have reached the current level of maturity where it is possible to achieve success in the recognition, but are not as efficient under varying lighting. Facial recognition systems that use infrared images are able to recognize faces in different lighting conditions or uncontrolled lighting. This paper presents a comparative study to carry out the stages of face recognition using infrared images. At the end we discuss the advantages of the techniques we use as a comparison of results.

Sumario

Resumo	i
Abstract	ii
Sumario	iii
Índice de Figuras	v
Tabela de Símbolos e Siglas	viii
Capítulo 1 Introdução	9
1.1 Objetivos	10
1.1.1 Objetivos Gerais	10
1.1.2 Objetivos Específicos	11
1.2 Metodologia	11
1.3 Estrutura do trabalho	12
Capítulo 2 Reconhecimento de Faces	13
2.1 Extração de Características	14
2.2 Métodos de Classificação	18
2.3 Dificuldades em Reconhecimento de Face	22
Capítulo 3 Imagens Infravermelhas	24
3.1 Iluminação	27
3.1.1 Influências da iluminação na imagem	28
3.2 Dispositivos de aquisição de imagens	30
3.3 Reconhecimento de faces infravermelhas	31

3.4 Ferramentas utilizadas	35
Capítulo 4 Experimentos e resultados	36
Capítulo 5 Conclusão	48
Referências	49

Índice de Figuras

Figura 1.	Etapas do Reconhecimento	13
Figura 2.	Matriz de treinamento X	16
Figura 3.	Matriz de covariância.....	17
Figura 4.	Hiperplano separando duas classes distintas [10]	21
Figura 5.	Espectro eletromagnético [13].....	24
Figura 6.	Imagem infravermelha em tom de cinza [15].....	26
Figura 7.	Imagem de satélite em infravermelho do estado de São Paulo [14].....	27
Figura 8.	Imagens A e A' em condições de iluminação diferentes representadas pelas imagens em infravermelho B e B', respectivamente [5].....	29
Figura 9.	Imagens capturadas pela câmera Raytheon [15]	31
Figura 10.	Imagens visíveis e infravermelhas em diferentes aspectos [5].....	32
Figura 11.	Imagens de faces A, B e C com expressões diferentes representadas pelas imagens infravermelhas D, E e F, respectivamente [5].....	34
Figura 12.	Imagem visível e infravermelha do mesmo sujeito usando óculos [5]..	34
Figura 13.	Imagens do banco <i>Terravic</i>	36
Figura 14.	Gráfico da taxa de reconhecimento.....	38
Figura 15.	Pessoa 5 sem equalização e com equalização do histograma	39
Figura 16.	Histograma sem equalização e com equalização da pessoa 5	39
Figura 17.	Gráfico obtido equalizando os histogramas.....	41

Figura 18. Gráfico da taxa de reconhecimento com disfarces.....43

Índice de Tabelas

Tabela 1.	Resultados obtidos variando a quantidade de características (KNN)	37
Tabela 2.	Resultados obtidos equalizando o histograma	40
Tabela 3.	Resultado obtidos com disfarces (KNN)	42
Tabela 4.	Resultados obtidos com SVM sem realizar extração de características	44
Tabela 5.	Resultados obtidos com SVM utilizando PCA	45
Tabela 6.	Resultados obtidos com SVM utilizando PCA com equalização	45
Tabela 7.	Resultado obtidos com disfarces (SVM)	46
Tabela 8.	Resumo do desempenho dos classificadores	47
Tabela 9.	Resumo do desempenho em imagens com disfarces	47

Tabela de Símbolos e Siglas

PCA – *Principal Component Analysis* (Análise de Componentes Principais)

KNN – *K-Nearest Neighbor* (K-vizinhos mais próximos)

SVM – Máquina de Vetor de Suporte (*Support Vector Machine*)

X – Matriz de treinamento do PCA

C – Matriz de covariância

Capítulo 1

Introdução

Processamento de imagens tem contribuído no desenvolvimento de várias áreas como engenharia, astronomia, medicina e segurança. Neste trabalho será estudada uma subárea de processamento de imagens, visão computacional, usando técnicas de reconhecimento de padrões através de métodos biométricos. Um sistema biométrico compara características físicas e comportamentais dos seres vivos para estabelecer um padrão de similaridade entre elas e identificá-los [1]. Um sistema de reconhecimento de faces é capaz de identificar seres humanos a partir de sua face. Atualmente, sistemas desse tipo são muito utilizados em aplicações de segurança, reforçando a qualidade e diminuindo a possibilidade de invasão.

Os investimentos mais recentes na área de segurança têm relação direta com a biometria. Um shopping de São Paulo, após sofrer treze assaltos em um período de três meses, implantou um sistema de monitoramento por câmeras de segurança capaz de reconhecer suspeitos em uma multidão de clientes, os cartões de crédito modernos exigem assinatura digital do comprador e os pacientes detentores de alguns planos de saúde precisam fazer autenticação através de impressão digital para serem atendidos pelos médicos credenciados.

Dentre os vários tipos de sistemas biométricos, talvez o mais intuitivo seja o de reconhecimento facial. Estudos científicos apontam que com poucos meses de vida o bebê é capaz conhecer sua mãe a certa distância em um grupo de pessoas. Através da face é possível diferenciar as pessoas no dia a dia, bem como determinar o estado emocional em que uma pessoa se encontra.

Imagens visíveis são as capturadas conforme a visão humana enxerga, ou seja, a câmera capta o que está visível a olho nu. Os sistemas de reconhecimento de faces que utilizam imagens visíveis são relativamente confiáveis em ambientes

controlados. Porém, sob circunstâncias em que não há controle de iluminação a tarefa do reconhecimento fica comprometida.

Imagens infravermelhas representam uma alternativa viável na busca de um sistema robusto de identificação. Reconhecer faces usando a tecnologia infravermelha é possível mesmo sem nenhum controle de iluminação, pois a luz na faixa do infravermelho é emitida, em vez de refletir e a emissão da pele é uma propriedade intrínseca, independente de iluminação. Portanto, as imagens capturadas com câmeras infravermelhas são praticamente invariáveis a mudanças de iluminação.

Neste trabalho são feitas comparações entre imagens de faces infravermelhas com objetivo de realizar com sucesso a tarefa de reconhecimento. Dada uma imagem de face infravermelha é possível identificá-la dentre as fotos infravermelhas do banco de imagens utilizado. São notórias as vantagens de se utilizar imagens infravermelhas, visualizando no banco de fotos usadas as poucas variações sofridas nas faces infravermelhas tanto devido à variação de iluminação, como variações de expressões. Por fim, é demonstrado através de uma detalhada análise dos resultados, que as faces foram identificadas corretamente.

1.1 Objetivos

1.1.1 Objetivos Gerais

O Trabalho de Conclusão de Curso em questão tem como objetivo principal modelar e implementar um ambiente para reconhecimento de faces, baseado em imagens infravermelhas. A meta principal é comparar os resultados obtidos com relação às técnicas que utilizam imagens de face no espectro visível.

1.1.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Confirmar que utilizar imagens infravermelhas é uma boa alternativa para os problemas de reconhecimento de faces (variações de iluminação e expressão facial);
- Motivar pesquisadores para o uso de imagens infravermelhas em reconhecimento facial.

1.2 Metodologia

Para realizar o reconhecimento de faces existem algumas etapas para serem seguidas. Será feito o processamento da imagem, seguido pela extração de características e posteriormente a classificação da imagem.

O banco de imagens selecionado possui 300 fotos de rostos em infravermelho, de 20 pessoas diferentes. Não será preciso fazer nenhum trabalho de rotação, pois todas as fotos foram tiradas de frente e a mesma distância.

Será feito uso de algoritmos para realizar a extração de características e classificação das imagens. Na extração das características reduziremos a dimensionalidade das imagens retornando somente as características mais visíveis e na classificação será comparado o objeto teste com o conjunto de atributos selecionados no treinamento.

Ao final dessas etapas será realizada a verificação que consiste em confirmar a identidade de uma pessoa, realizando comparações com outras técnicas que não utilizam tecnologia infravermelha. E, por fim, o reconhecimento completo, que determina se uma imagem pertence ou não a uma classe, determinando sua identidade.

1.3 Estrutura do trabalho

O trabalho encontra-se dividido nos seguintes capítulos:

- Capítulo 2: Trata dos fundamentos das técnicas de extração de características e classificadores utilizados neste trabalho, uma descrição das dificuldades relacionadas ao reconhecimento facial;
- Capítulo 3: Disserta sobre as vantagens de utilizar imagens infravermelhas para reconhecimento facial e descreve a metodologia usada para classificação das imagens utilizadas neste trabalho;
- Capítulo 4: Trata da apresentação e discussão dos resultados obtidos no emprego da metodologia;
- Capítulo 5: Dispõe sobre as conclusões finais do trabalho e proposta para trabalhos futuros.

Capítulo 2

Reconhecimento de Faces

Os seres humanos sempre utilizaram as características do corpo como referência para identificação uns dos outros como, por exemplo, voz e face. Certamente, a aparência da face é o primeiro método de reconhecimento entre pessoas.

A biometria trata da análise de medidas biológicas de indivíduos, visando, entre outras aplicações, seu futuro reconhecimento. O reconhecimento de face têm se destacado em relação aos demais métodos de identificação de pessoas, como impressão digital, assinatura digital e íris. A dificuldade de representar uma face de modo a abstrair as características que a diferenciam de outras faces é o principal problema do reconhecimento de faces, pois as faces apresentam poucas diferenças substanciais entre elas (em todas será preciso localizar olhos, nariz, boca e contornos da face) [2].

O reconhecimento de faces é uma particularização do problema geral de reconhecimento de padrões e pode ser ilustrado como na Figura 1:

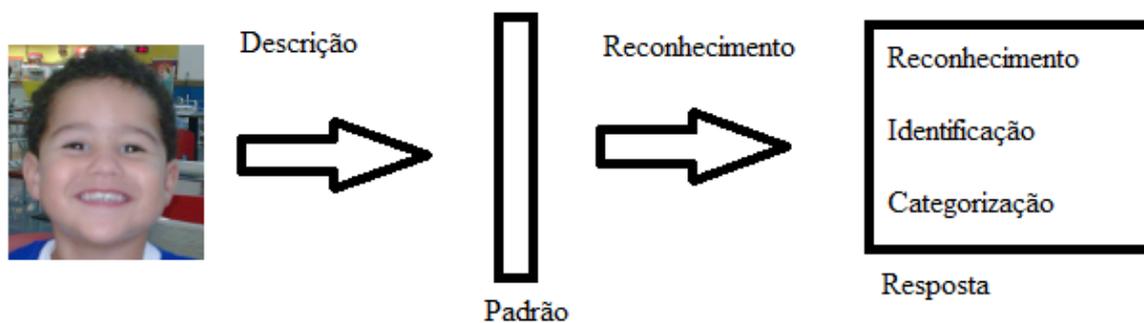


Figura 1. Etapas do Reconhecimento

O reconhecimento de face consiste em confirmar se uma imagem de face é conhecida pelo sistema. Não é necessário realizar a ligação da face a um nome e sim atribuir-lhe uma classificação: conhecida ou desconhecida.

A identificação deve realizar o reconhecimento e associar uma identidade à face apresentada. Já a categorização, compreende as tarefas de identificação de sexo, raça ou estado emocional da imagem apresentada. Ela pode também ser aplicada na definição de qual biotipo a face se encaixa, segundo um padrão de estética adotado. A etapa de classificação é realizada após a extração das características, e que possui vários métodos diferentes para sua execução.

2.1 Extração de Características

O processo de extração de características produz uma representação computacional da imagem obtida, que é chamada de atributos ou características extraídas. A extração de características é a redução de um conjunto de medidas formado por uma grande quantidade de dados que contém uma pequena quantidade de informação útil para um conjunto que contém menos dados, mas que contém praticamente a mesma quantidade de informação [3].

As razões para reduzir a dimensionalidade de uma imagem são: custo de medição e precisão do classificador. Se o espaço característico contiver somente as características mais visíveis, o classificador será mais rápido e ocupará menos memória [4].

Vários métodos de redução de dimensionalidade têm sido desenvolvidos para reduzir as representações das imagens. Este processo torna o problema de reconhecimento facial computacionalmente tratável. Alguns métodos de extração de características utilizam como característica discriminatória dos indivíduos as características geométricas, onde se medem, por exemplo, posições da boca, do nariz, a distância entre os olhos e tamanho do nariz [5]. O método de extração de características usado neste trabalho faz uma análise estatística dos dados da face, a

partir do método Análise de Componentes Principais (PCA – *Principal Component Analysis*).

2.1.1 Análise de Componentes Principais (PCA)

Para solucionar o problema da alta dimensionalidade das imagens podem ser utilizados métodos estatísticos de redução de dimensionalidade, como PCA, que tem por finalidade identificar o melhor arranjo que representa a distribuição dos dados [4]

O PCA analisa os dados gerados a partir das imagens, visando sua redução, eliminação de sobreposições e a escolha das formas mais representativas de dados a partir de combinações lineares das variáveis originais.

Levando em consideração que uma imagem pode ser representada pela matriz de pixel ($h \times m$), o método que emprega Análise de Componentes Principais (PCA) sugere que a matriz de características $h \times m$ deve ser transformada para o espaço linear, no qual cada pixel dessa imagem pode ser colocado em um vetor coluna, construído a partir da leitura coluna por coluna da imagem original, que é inserido em uma matriz X [4]. A partir do valor dos pixels de cada imagem, os vetores colunas são inseridos em uma matriz X , obtida através da Equação 1 [4]:

$$X_{i,j+(k-1)} = I_{j,k}^i \quad (1)$$

Para esta equação, dada uma matriz I_i de h linhas e w colunas representando a imagem i , para $j = 1, 2, 3, \dots, w$, $k = 1, 2, 3, \dots, h$ e $i = 1, 2, 3, \dots, n$, em que n é o número de colunas e $h \cdot w = M$. Cada coluna da matriz X representa um vetor imagem, conforme a Figura 2. Onde P_1, P_2 e P_n representam imagens de faces.

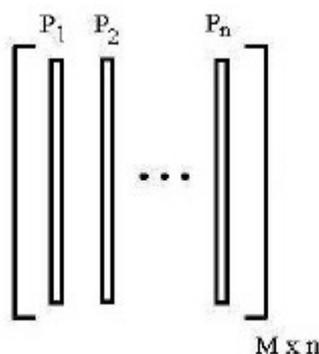


Figura 2. Matriz de treinamento X

Imagens de faces são demasiado redundantes, devido ao fato de que cada pixel ser altamente correlacionado com outros pixels. Além disso, como faces diferentes possuem características comuns, como olhos, nariz e boca, vetores que representam faces distintas também podem ser bastante correlacionados. Em reconhecimento de padrões, almeja-se que não exista covariância entre as bases do espaço de características. Em teoria da probabilidade, covariância entre duas variáveis aleatórias é uma medida estatística de como duas variáveis variam conjuntamente. A técnica PCA se baseia em reduzir o máximo possível a covariância existente entre os vetores que representam as imagens.

Para verificar se há covariância entre as características (ou variáveis), utiliza-se a matriz de covariância dos padrões. Seja X a matriz que representa os vetores imagens de treinamento, seja μ a média de tais vetores e seja $(x_i - \mu)$ o vetor que representa a diferença da face associado ao vetor x_i em relação à média de sua classe. A matriz de covariância de X pode ser obtida conforme a Equação 2 [4]:

$$C = (X - \mu)(X - \mu)^t, \quad X = [x_1, x_2, x_3, \dots, x_n] \quad (2)$$

Em que μ é a matriz $M \times n$, em que todas suas colunas contêm o valor esperado de X , o qual pode ser obtido pela média aritmética das colunas de X . Ou seja [4]:

$$\mu_{l,i} = \frac{1}{n} \sum_{i=1}^n X_{l,i}, l = 1,2,3,\dots,M \quad (3)$$

A Figura 3 expõe a matriz de covariância entre os vetores imagens da matriz de treinamento X :

$$C = \begin{bmatrix} E[(X_1 - \mu_1)(X_1 - \mu_1)] & E[(X_1 - \mu_1)(X_2 - \mu_2)] & \cdots & E[(X_1 - \mu_1)(X_n - \mu_n)] \\ E[(X_2 - \mu_2)(X_1 - \mu_1)] & E[(X_2 - \mu_2)(X_2 - \mu_2)] & \cdots & E[(X_2 - \mu_2)(X_n - \mu_n)] \\ \vdots & \vdots & \ddots & \vdots \\ E[(X_n - \mu_n)(X_1 - \mu_1)] & E[(X_n - \mu_n)(X_2 - \mu_2)] & \cdots & E[(X_n - \mu_n)(X_n - \mu_n)] \end{bmatrix}$$

Figura 3. Matriz de covariância.

Para uma matriz de covariância C , vale a expressão $C^*u = \lambda^*u$, onde os vetores u são chamados de autovetores e os valores λ são chamados de autovalores. PCA tem como ideia principal representar as faces por poucos parâmetros. Isso só é possível encontrando os autovetores que melhor diferenciem a distribuição das faces. Os autovetores, neste contexto também chamados *eigenfaces*, transpõem um vetor para um novo espaço chamado espaço de faces. Autovetores disponibilizam informações sobre padrões nos dados. Após o cálculo dos autovetores, deve-se ordená-los a partir dos autovalores associados, formando um grau decrescente de representatividade do conjunto. Os maiores autovalores estão associados com os autovetores que descrevem padrões no conjunto de dados [6].

A variação no conjunto de dados pode ser apropriadamente descrita por poucas variáveis que retenham as maiores variâncias, se a maioria das variáveis apresentarem variâncias tão pequenas ao ponto de serem ignoradas.

2.2 Métodos de Classificação

A etapa de classificação considera apenas o conjunto de atributos selecionados no treinamento e tem a finalidade de comparar os objetos de teste e um conjunto de classes de objetos usados no treinamento, indicando a qual classe o objeto pertence. Como, uma classificação computacional perfeita é impossível, a classificação é realizada baseada em probabilidade, fornecendo um grau de semelhança do objeto de teste em relação a sua classe. É o grau de semelhança que indicará a que classe o objeto pertence, ou seja, de qual classe o objeto de teste se aproxima mais.

Neste trabalho serão usados dois métodos de classificação diferentes: *k* vizinhos mais próximos (KNN - *k-Nearest Neighbor*) e Máquina de Vetor de Suporte (SVM - *Support Vector Machines*).

2.2.1 K-Vizinhos mais Próximos (K-NN)

O algoritmo de classificação dos *k*-vizinhos mais próximos é bastante simples e intuitivo, pois classifica um exemplo de acordo com a sua semelhança em relação ao conjunto de treino. Entretanto, ao invés de classificar a face de teste como a primeira face de treinamento mais próxima, ele identifica as *k* faces mais próximas e classifica a face de teste considerando a classe que for mais frequente entre as *k* faces de treinamento mais próximas [7].

A vantagem do KNN é que, quando o conjunto de treinamento é muito grande, ele se adapta à forma de distribuição dos dados de treinamento, resultando em boas taxas de acertos. Para diminuir a ocorrência de erros causados por ruído no padrões de treinamento utiliza-se $K > 1$, porém o uso de valores muito grandes

para k pode resultar na redução da taxa de acertos, principalmente quando a distribuição das classes apresenta um número elevado de sobreposições [7].

Sejam $\{y_{1j}, y_{2j}, \dots, y_{mj}\}$ os m coeficientes selecionados para representar a pessoa j e sejam $\{w_{1jk}, w_{2jk}, \dots, w_{mjk}\}$ os coeficientes de treinamento da pessoa j na pose k .

O classificador KNN classifica a face f baseado nos seguintes passos [7]:

1. Calcula-se a distância entre a face f e a pessoa de treinamento j na pose k , com $j=1, 2, \dots, p$ e $k=1, 2, \dots, q$, dada por:

$$DKNN_{fjk} = \sum_{i=1}^m |w_{ijk} - y_{if}| \quad (4)$$

2. Identificam-se os k menores valores $DKNN_{fjk}$ e define-se o i -ésimo vizinho mais próximo como a pessoa j associada ao i -menor valor de $DKNN_{fjk}$, com $i=1, 2, \dots, k$;
3. A classificação da pessoa f corresponde então à pessoa j mais frequente entre os k -vizinhos identificados;
4. Em caso de empate, será adotada a abordagem NN para desempate, ou seja, escolhe-se a classe que corresponde ao primeiro vizinho mais próximo.

2.2.1 Máquina de Vetor de Suporte (SVM)

O aprendizado de máquina baseia-se em inferência por indução para coletar informações de um determinado conjunto e, a partir desses dados, realizar conclusões para que a máquina possa aperfeiçoar seu desempenho em alguma tarefa. Aprendizado indutivo pode ser subdividido em supervisionado, no qual cada classe do conjunto de exemplo é conhecida, e não-supervisionado onde a classe a que pertence o conjunto de exemplo não é conhecida [8].

SVM é uma técnica de aprendizado supervisionado de máquina baseada em aprendizagem estatística, que foi introduzida em 1992 por Vapnik [8]. O aprendizado estatístico visa obter uma função que minimize o risco funcional através das relações extraídas de um determinado conjunto. É natural que se minimize o erro durante a fase de treinamento, e é esperado que o mesmo aconteça com o restante do conjunto de dados. A quantidade de classificações incorretas com respeito às amostras é chamada de risco empírico. Sendo assim, o risco empírico mede o desempenho do classificador nos dados de treino. Com isso, SVM tenta minimizar o risco esperado, que é obtido através daquele risco em relação a função de distribuição de probabilidade dos dados [8].

SVM tem a finalidade de encontrar um hiperplano que separe uma série de pontos definidos em um espaço multidimensional. Originalmente, SVM foi desenvolvida para solução de problemas binários, de duas classes distintas. Porém, usando as técnicas adequadas, este método pode ser adaptado para solucionar problemas multiclases [9].

A ideia principal é que dados dois conjuntos, é necessário encontrar um hiperplano que os separe e maximize as distâncias (margens) entre este e as amostras mais próximas de cada conjunto, conforme exposto na Figura 4A. As SVMs são responsáveis por encontrar o melhor hiperplano que divida o conjunto de dados. Mas, na prática, dificilmente os dados de treinamento serão linearmente separáveis. Sendo assim as SVMs podem permitir que alguns dados permaneçam entre as margens de separação (margens suaves), conforme na Figura 4B, ou mapeiam o espaço original de entrada, para um espaço com dimensão maior, denominado espaço de características (SVMs não lineares), como na Figura 4C. Neste novo espaço de características, escolhendo a função de mapeamento correta, é possível que os dados sejam linearmente separáveis [10].

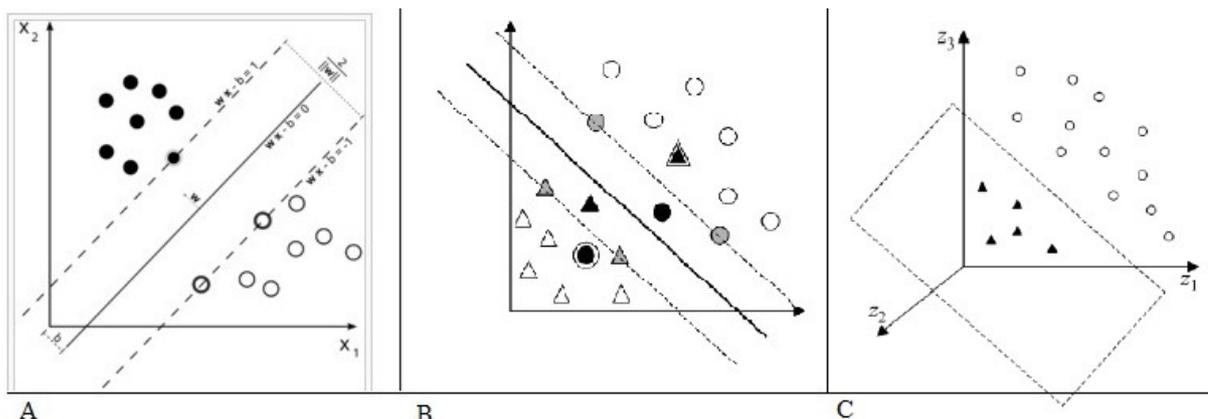


Figura 4. Hiperplano separando duas classes distintas [10]

O cálculo de produto escalar entre os dados do espaço de características é realizado através do uso das funções de kernel. Estas funções trabalham da seguinte forma: dados dois pontos no conjunto de entradas elas os recebem e computam o produto escalar desses dados no espaço características. As funções de kernel utilizadas neste trabalho são:

- Kernel Polinomial: $K(x_i, x_j) = (s x_i^T x_j + c)^d$, $d > 0$
- Kernel Linear: $K(x_i, x_j) = x_i^T x_j$

Onde $K(x_i, x_j)$ é uma função simétrica, em que x_i e x_j pertencem ao espaço de entrada. Os dados que estão no espaço de entrada não são separáveis por um hiperplano. Estas funções fazem uma transformação nos dados de maneira que, no espaço de características, tornam-se separáveis. O parâmetro d da função de kernel polinomial é o grau do polinômio, c é uma constante e s é uma constante negativa.

No caso de reconhecimento facial, em que o problema é multiclass, é possível, realizando algumas modificações, estender SVM para trabalhar com mais de duas classes. Existem duas estratégias para realizar esta adaptação: diretas e decompositivas. A primeira propõe a reformulação do algoritmo original para o

problema multiclases, o que pode gerar algoritmos de difícil realização e computacionalmente caros. Na estratégia decomposicional o espaço de características multiclases é dividido em pares binários, possíveis de serem separados por hiperplanos binários. No final deste processo as saídas dos classificadores encontrados são recombinaados, determinando um padrão de classificação do problema original [10].

As estratégias decompositivas podem ser realizadas usando duas técnicas diferentes: um-contra-todos e todos-contra-todos. Na primeira, para cada uma das k classes do problema é definido um hiperplano que separa os elementos dessa classe de outra classe artificial formada por todos os outros exemplos. Portanto, são necessários k hiperplanos para identificar uma das classes do problema. Na técnica todos-contra-todos, para cada par possível dentre as k classes desejadas, é definido um hiperplano que separa o par. Portanto são necessários $k(k-1)/2$ hiperplanos para identificar uma das classes do problema [11].

2.3 Dificuldades em Reconhecimento de Face

Em geral os algoritmos de reconhecimento de faces são avaliados em ambientes controlados, por exemplo, dentro de um quarto, onde não há muita variação de iluminação.

A principal dificuldade encontrada em sistemas de reconhecimento de faces está na grande quantidade de variações possíveis em que as imagens de faces podem ser capturadas. Os mais relevantes problemas relacionados às variações são as seguintes: a pose de uma face (que pode variar entre frontal e perfil); a presença ou ausência de componentes faciais como óculos, maquiagem, barba ou bigode; o envelhecimento da pessoa e conseqüentemente do aspecto da sua face; a orientação da cabeça; as diferentes expressões faciais que mudam a aparência de uma face; a escala em que a face foi capturada; a possibilidade de oclusão das faces; o *background* das imagens onde se verifica a existência de faces e por fim as

diferentes condições de captura da imagem como a luminosidade e a resolução da fotografia [2] [4] [7].

O sistema deve ser robusto para tentar minimizar os problemas típicos de aquisição de imagens como o ruído, distorção que ocorre na câmera fotográfica, e resolução de imagem. A luz refletida nos rostos humanos também varia significativamente de pessoa para pessoa. Esta variabilidade, juntamente com as condições de iluminação dinâmica, causam sérios problemas.

Faces humanas de diferentes grupos étnicos também têm características espectrais diferentes. O problema de encontrar invariantes relacionadas à cor da pele no espectro visível pode ser facilmente resolvido com um sensor infravermelho calibrado.

Considerando as dimensões comuns às imagens de faces, o tempo necessário para a realização do reconhecimento também tem sido visto como uma dificuldade. Nesse contexto, devem-se utilizar bons algoritmos de redução da dimensionalidade dos dados, que sejam capazes de extrair das imagens somente as informações essenciais para o reconhecimento.

Dessa forma, os métodos de reconhecimento de faces normalmente têm como objetivo reconhecer com confiabilidade e independente de fatores que possam provocar variações nas imagens de uma mesma face.

Capítulo 3

Imagens Infravermelhas

A radiação infravermelha é uma radiação não ionizante na porção invisível do espectro eletromagnético que está adjacente aos comprimentos de onda longos, ou final vermelho do espectro da luz visível [12]. A Figura 5 expõe uma distribuição do espectro eletromagnético. A radiação infravermelha foi descoberta pelo alemão Friedrich Wilhelm Herschel, em 1800, que, com seus experimentos percebeu que o calor era mais forte ao lado do vermelho do espectro, observando que ali não havia luz. Herschel demonstrou que o calor pode ser captado em forma de imagem, como acontece com a luz visível [13].

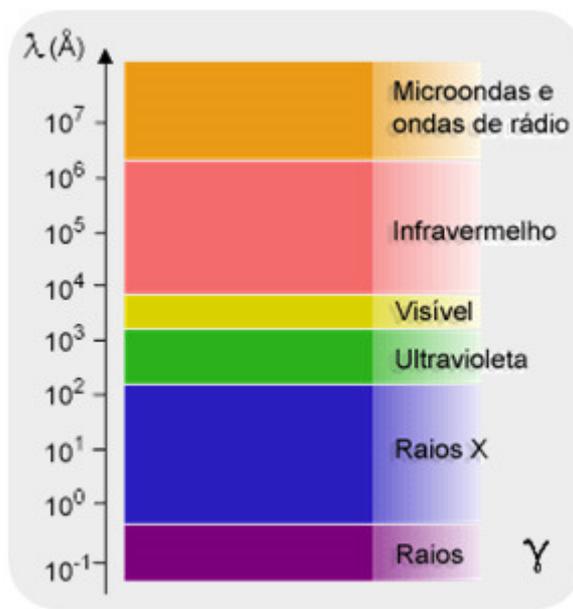


Figura 5. Espectro eletromagnético [13]

Herschel estudava as cores do espectro solar transmitidas através de filtros que permitiam a passagem de apenas uma cor quando observou que cada um dos filtros deixava passar uma quantidade específica de calor. A partir de um experimento que media a temperatura das diferentes cores ele verificou que a temperatura diminuía do vermelho para o violeta. Ao medir essa temperatura da região do espectro antes da cor vermelha, Herschel notou que era superior àquela emitida pelo vermelho. Assim, Herschel demonstrou a existência de uma nova forma de luz, invisível, e a chamou de infravermelho [14].

O termo “*infra*” em latim significa “em baixo de” ou “abaixo de”, desta forma a região do infravermelho é a região abaixo do vermelho. O termômetro foi o primeiro sensor utilizado pelos pioneiros na investigação desta nova forma de radiação eletromagnética. Desde a descoberta por Herschel até o fim dos anos 30, o desenvolvimento na região do infravermelho foi lento e voltado principalmente à sensores térmicos [12]. A aplicação em reconhecimento de faces, como será apresentado mais adiante, se deve ao fato do infravermelho ser independente de iluminação.

O infravermelho é uma radiação do espectro eletromagnético com comprimentos de onda entre $0,75 \mu\text{m}$ a $100 \mu\text{m}$, em meio ao limite da percepção visual do vermelho e as micro-ondas [14]. Enquanto as câmeras visíveis são capazes de capturar a energia eletromagnética na faixa do espectro visível ($0,4-0,7 \mu\text{m}$), sensores na câmera infravermelha podem captar a radiação térmica no intervalo do espectro infravermelho de $0,7-14,0 \mu\text{m}$. O espectro infravermelho compreende o infravermelho refletido e as bandas de frequência térmica de infravermelho.

A região do infravermelho pode ser subdividida em quatro partes [13]:

- Infravermelho próximo – região de $0,75\mu\text{m}$ (400THz) a $3\mu\text{m}$ (100THz).
- Infravermelho médio – região de $3\mu\text{m}$ (100THz) a $6\mu\text{m}$ (50THz).
- Infravermelho distante – região de $6\mu\text{m}$ (50THz) a $15\mu\text{m}$ (20THz).

- Infravermelho extremo – região de $15\mu\text{m}$ (20THz) a 1mm (300GHz).

Devido ao fato das faixas do infravermelho médio e do infravermelho distante possuírem condições de propagação mais favoráveis, estas regiões são mais interessantes para as tarefas de detecção e reconhecimento. Um exemplo de imagem infravermelha pode ser visto na Figura 6. Esta imagem representa a quantificação e caracterização da energia térmica emitida por um objeto captado por um detector de radiação infravermelha. Trata-se de um mapeamento bidimensional em tons de cinza.



Figura 6. Imagem infravermelha em tom de cinza [15]

A fotografia é uma atividade muito beneficiada com a aplicação da radiação infravermelha. Dependendo do tipo de filme colocado na máquina, podemos obter resultados diferentes, posto que as cores dos objetos apresentam-se deslocadas de suas posições no espectro - a luz azul não aparece, os objetos verdes ficam azuis, os vermelhos mostram-se verdes e os infravermelhos colorem-se de vermelho [14].

As imagens em infravermelho podem ser aplicadas em diversas áreas de atuação como, na Figura 7, imagem obtida via satélite para o monitoramento do

meio ambiente. A partir dessa aplicação é possível monitorar o aumento da poluição urbana, as queimadas em florestas ou a temperatura da superfície do mar. Em sistemas voltados para a área de segurança, o infravermelho é importante nas operações de detecção e reconhecimento.

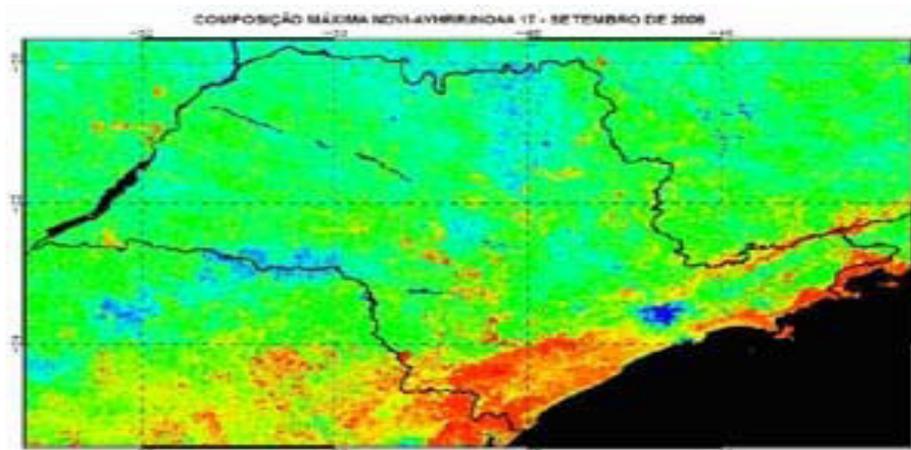


Figura 7. Imagem de satélite em infravermelho do estado de São Paulo [14]

3.1 Iluminação

A iluminação afeta diretamente a qualidade das fotos. As melhores imagens são adquiridas com máxima iluminação solar e céu limpo. Um dos problemas na aquisição de imagens está relacionado às condições de iluminação. A expressão fotografia significa “gravar com luz”, por isso que a iluminação é tão importante para realização de fotografias.

No espectro visível a cor dos objetos na cena depende da iluminação que recebem. Para fotografar podem ser utilizados dois tipos de iluminação: natural e artificial. Iluminação natural é proveniente da fase do dia, ou seja, da luz solar. As fontes de luz artificiais podem ser de vários tipos e potências diferentes. Quando

uma fonte geradora de luz artificial não esquentada, ela é chamada de luz fria, pois não esquentada e evita que o modelo transpire.

3.1.1 Influências da iluminação na imagem

A luz é um valor de composição fundamental para a fotografia. Assim como o pintor necessita lidar com as tintas para compor sua obra, o fotógrafo precisa da luz para registrar a imagem num plano. Entre os elementos que dão vida à fotografia, a luz tem a função de captar e registrar as nuances nas imagens em cores e as gradações de cinza nas fotografias em preto e branco [16].

O posicionamento da câmera e a escolha do melhor local e horário podem alterar a textura, o volume, o contraste e a coloração fotográfica. As variações da luz solar podem compor distintas cenas dependendo do horário escolhido para o instante fotográfico. A qualidade da luz natural é influenciada não apenas pelo horário do dia, mas pelas condições atmosféricas, pela época do ano e também pela localização geográfica.

Tanto a luz natural quanto a artificial podem diferenciar-se na qualidade da imagem, o que pode resultar em uma imagem mais contrastada e agressiva, com maior variação de tonalidades. Esse fato acentua os detalhes e as sombras nos objetos. O contraste na fotografia é uma relação entre a luz, que recai nas partes iluminadas, e a luz das partes sombreadas do objeto [16].

A direção da luz também influencia no resultado final da imagem capturada. Seja a partir da luz natural ou artificial, a direção da fonte de luz determina onde será projetada a luz e a sombra do objeto, o que afeta o aspecto da textura e o volume. Para ser mais específico, variações na direção e na distribuição da iluminação ambiente, juntamente com a estrutura 3D do rosto humano, pode levar a diferenças importantes no sombreado das faces. Tais variações na aparência facial podem ser muito maior do que a variação causada pela identidade da pessoa.

3.1.2 Independência de Iluminação

As câmeras infravermelhas podem fornecer claros sinais a imagem durante o período diurno e noturno e até mesmo em certas situações meteorológicas adversas, tais como condições nebulosas.

As câmeras de visão noturna mais baratas são aquelas que possuem lentes e sistemas eletrônicos que amplificam a pouca luz que conseguem capturar em um ambiente escuro. Este tipo de tecnologia é muito usado em câmeras de vigilância. Atualmente também existe webcam de visão noturna.

Para colocar uma câmera de visão noturna em um local totalmente fechado e escuro é necessário utilizar uma iluminação de infravermelho. A luz emitida não pode ser vista pelas pessoas, mas pode ser identificada pelo equipamento. Existem muitas câmeras de vídeo mais sofisticadas que já possuem algum tipo de visão noturna, normalmente deixa a filmagem com tons de verde e possui uma iluminação infravermelha artificial.

Quando afirmamos que imagens infravermelhas independem de iluminação é que quando capturamos o mesmo objeto via um captor de infravermelho sob condições diferentes de iluminação este sofre pouca variação. Na Figura 8 fica fácil perceber esta invariância.

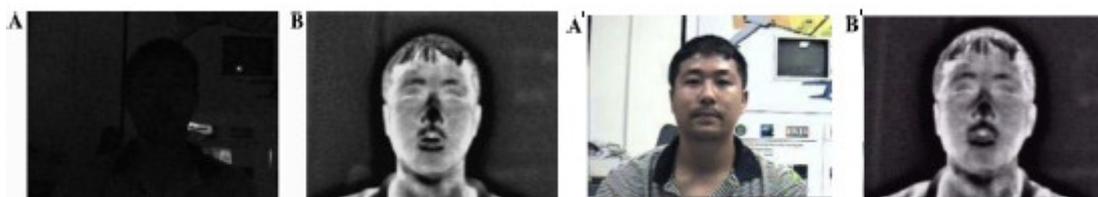


Figura 8. Imagens A e A' em condições de iluminação diferentes representadas pelas imagens em infravermelho B e B', respectivamente [5].

Não é necessário controle da iluminação para captura de imagens com máquinas infravermelhas. A fotografia de uma face infravermelha terá resultado semelhante com ou sem luz.

3.2 Dispositivos de aquisição de imagens

Atualmente, são várias as opções de câmeras de infravermelho de mercado, principalmente na área de segurança. O custo reduzido das atuais máquinas fotográficas infravermelho facilitou o acesso às mesmas e possibilitou a difusão de vários estudos na área. Como exemplo é possível citar a câmera de visão noturna ATX 3115, que possui sensor de imagem com iluminadores infravermelhos com alcance máximo de 15 metros. Visualiza as imagens noturnas com iluminação zero e possui tecnologia que a torna eficiente tanto durante o dia como no período noturno.

As imagens infravermelhas de faces utilizadas neste projeto de pesquisa, como as da Figura 9, foram capturadas pela câmera *Raytheon L-3 Thermal-Eye 2000AS*, que não é capaz de realizar medição de temperatura. Esta câmera é mais adequada para a vigilância, manutenção preventiva, investigação e desenvolvimento, e aplicações médicas. A câmera tem uma saída de vídeo, tomada e pode armazenar imagens analógicas em fita de vídeo ou digital usando um dispositivo de gravação digital opcional. A câmera Raytheon detecta ondas de 46,8 μm .



Figura 9. Imagens capturadas pela câmera Raytheon [15]

3.3 Reconhecimento de faces infravermelhas

Para reconhecimento de faces deve ser levado em consideração a aparência da face humana, que pode ser modificada por aspectos como iluminação, pose, expressão facial, idade, oclusão, adornos, etc [17]. Para comparações e testes são necessários banco de dados de faces que possuam variações de tais aspectos. Com imagens visíveis de faces 2D a relação de alguns aspectos modificadores da face humana influenciam negativamente nos resultados em comparação aos resultados com imagens infravermelhas. São eles a iluminação e a expressão facial.

Os atuais sistemas de reconhecimento de face baseado em imagens visíveis têm evoluído significativamente. No entanto, o desempenho desses sistemas é prejudicado sob condições de iluminação deficiente ou por variações de expressões. Estes problemas podem ser solucionados utilizando imagens infravermelhas, como é possível perceber a pouca variação sofrida nas imagens da Figura 10, em busca de um sistema robusto de identificação de padrões.

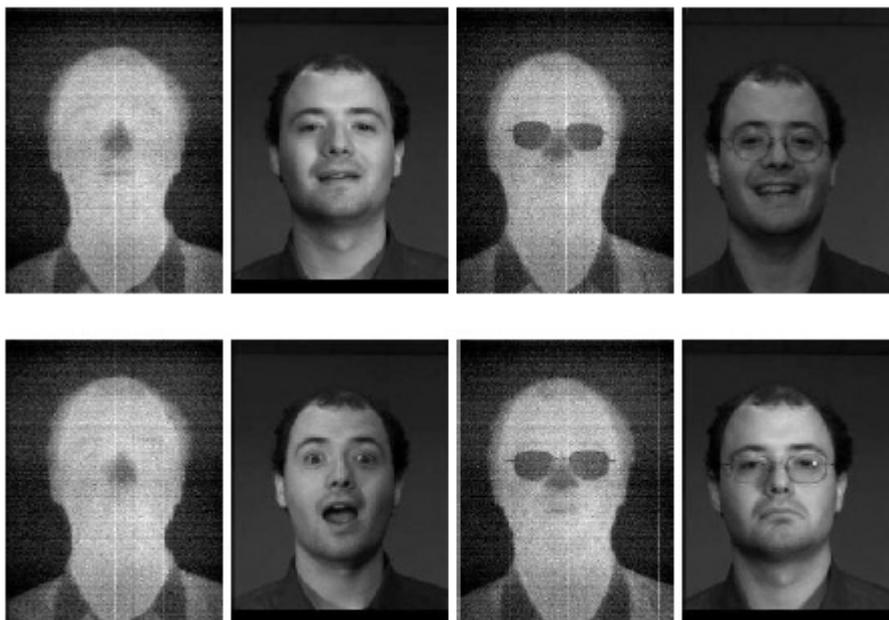


Figura 10. Imagens visíveis e infravermelhas em diferentes aspectos [5]

Iluminação infravermelha de baixa potência, invisível ao olho humano, pode ser usada para suplementar o processo de detecção da face. As imagens infravermelhas contêm mais informações fundamentais sobre os rostos. Sistemas de reconhecimento de face infravermelho são vantajosos quando não há nenhum controle sobre iluminação [18].

Alguns pesquisadores afirmam que o sistema biométrico deve se adaptar ao ambiente, não o contrário. Stan [19] desenvolveu um sistema de hardware de imagem para produção de imagens de faces com boa condição de iluminação. Nesta aplicação luzes ativas de infravermelho próximo são usadas para iluminar a face na direção frontal durante a aquisição da imagem. Neste caso, aplica-se a luz frontalmente porque variações no ângulo de iluminação podem acarretar futuros problemas de iluminação das imagens. É usada iluminação poderosa o suficiente para permanecer ativa no ambiente interno ao mesmo passo que é reduzido o espectro visível usando um filtro óptico. Como a face é iluminada na direção frontal e

com o efeito da luz visível minimizado, este sistema constitui uma excelente base para reconhecimento de faces [19].

Existem pesquisadores que preferem tratar o problema de variação de iluminação através de métodos diferentes. Xuan [20] divide esses métodos em duas categorias diferentes: passivos e ativos. Os métodos passivos tentam superar este problema, estudando as imagens do espectro visível, para analisar em que a aparência facial tem sido alterada pela variação de iluminação. Já os métodos ativos analisa como o problema de variação de iluminação é superado empregando técnicas ativas de aquisição de imagens de faces capturadas em condições de iluminação constante [20].

Reconhecimento de face é essencial para interpretar as expressões faciais, emoções humanas, e comportamento, que é um componente chave para ambientes inteligentes. Apesar do crescente sucesso das técnicas de reconhecimento automático de faces em várias aplicações, condições operacionais descontroladas tornam o reconhecimento baseado em espectro visível muito instável. A variação de iluminação é um dos principais fatores prejudiciais ao desempenho de sistemas de reconhecimento de faces visíveis. Outros fatores também interferem no desempenho desses sistemas, como, por exemplo, a expressão de face [19].

Além de possuir a qualidade de ser independente de iluminação as imagens de faces infravermelhas também sofrem pouca variação quando o sujeito altera a expressão do rosto. Na Figura 11 é possível perceber esta característica das imagens infravermelhas.

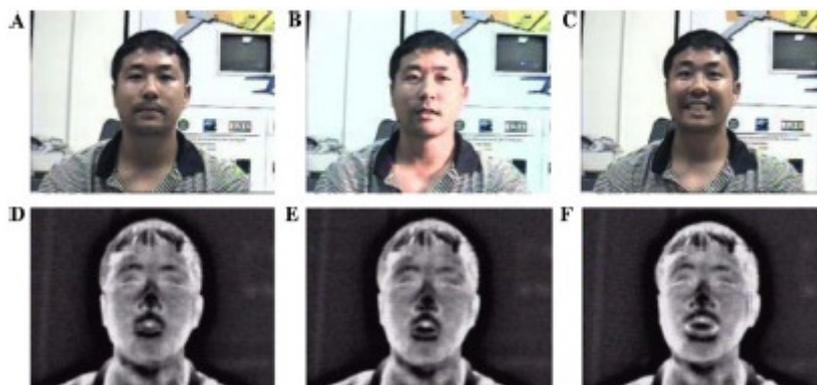


Figura 11. Imagens de faces A, B e C com expressões diferentes representadas pelas imagens infravermelhas D, E e F, respectivamente [5]

O uso de imagens infravermelhas para reconhecimento tem limitações em situações tais como o reconhecimento de uma pessoa com óculos. Os blocos de vidro resultam em uma perda de informação perto dos olhos, diminuindo a taxa de reconhecimento. As Figuras 12 A e B ilustram as aparências visível e térmica de uma face com óculos.



Figura 12. Imagem visível e infravermelha do mesmo sujeito usando óculos [5]

Reconhecimento de faces usando imagens infravermelhas é uma técnica em crescente uso, ao mesmo passo que imagens térmicas infravermelho se tornaram

uma alternativa bastante utilizada na detecção e reconhecimento de faces. As imagens de rosto capturadas com sensores infravermelhos são quase invariáveis a alterações de iluminação.

Câmeras visíveis representam a informação de refletâncias de um objeto de face, enquanto máquinas infravermelhas medem informações anatômicas. A Figura 8 mostra as características de imagens visíveis e infravermelhas com variações na iluminação e expressão facial. Infravermelho tem limitações em situações tais como o reconhecimento de uma pessoa usando óculos ou sentado em um veículo em movimento.

3.4 Ferramentas utilizadas

- O método de extração de característica e os classificadores utilizados neste trabalho foram elaborados na ferramenta MATLAB®2010;
- Todos os testes foram executados em um computador com processador Pentium Dual-Core T4500, com 2 GB de memória principal, executando o sistema operacional Windows 7.

Capítulo 4

Experimentos e resultados

Nesse trabalho, o banco de faces infravermelhas definido para testes foi o *Terravic* [15], que apresenta variações de iluminação, posição, expressão facial e presença de óculos e de cobertura. Ele está disponível na *web* para *download* sem necessidade de pedido ou de senha. Foram utilizadas 300 imagens 240 x 320 pixels, referentes a 20 pessoas, em várias poses diferentes. Na Figura 13 são ilustradas imagens do banco de faces *Terravic* apresentando oito pessoas em três situações diferentes de expressão, iluminação e disfarce.



Figura 13. Imagens do banco *Terravic*.

Conforme descrito no capítulo 2, foi utilizada PCA para determinar as características mais discriminantes entre todas as imagens das faces utilizadas no treinamento. Nesta etapa é calculada a imagem média da base de treinamento,

conforme a Equação 1, a matriz de covariância, assim com descrito nas Equação 2 e 3. Os autovetores da matriz de covariância e o vetor de características, que neste trabalho, varia de 10 a 30, é calculado após estas etapas. A mesma operação também deverá ocorrer para a imagem de teste.

A taxa de acertos dos classificadores é calculada baseada nos resultados dos testes realizados. Inicialmente foram realizados experimentos utilizando o classificador KNN. Os primeiros testes foram realizados com 14(quatorze) imagens de cada indivíduo, em poses diferentes com e sem óculos e/ou usando cobertura (chapéu, toca, boina, etc.). A taxa de acerto foi calculada através da média aritmética de 30 execuções de teste em que foram selecionadas aleatoriamente 10(dez) para compor a base de treinamento e 4 (quatro) para compor a base de testes, em cada uma das execuções. A mesma seleção randômica foi utilizada para os dois métodos classificadores.

Posteriormente é feita uma comparação entre as características principais ressaltadas pelo PCA, utilizando o classificador KNN, com o k variando de 1 a 7, sendo ele sempre ímpar para diminuir a chance de que ocorra empate. Em caso de empate será utilizado o classificador 1-NN. Na Tabela 1 estão descritos os resultados obtidos para quatro valores diferentes de k com o vetor características variando de 10 a 30.

Tabela 1. Resultados obtidos variando a quantidade de características (KNN)

Quantidade de Características	Classificação – Taxa de acerto em Porcentagem (%)			
	K = 1	K = 3	K = 5	K = 7
10	88,33	83,04	79,92	78,33
20	90,96	85,33	83,33	81,21
30	91,46	85,58	84,00	81,75

Com o valor *default* de k igual a 1 do classificador KNN, é possível obter melhores resultados, devido ao tamanho da base de treino em relação a base de teste. Além disso, imagens muito similares podem se repetir no treino e no teste tornando o k igual a 1 a melhor hipótese. Trata-se, pois, da menor distância euclidiana encontrada entre a base de treinamento e a imagem de teste. É possível perceber que melhores são resultados obtidos limitando as características extraídas em 30. No gráfico exposto na Figura 14 é possível visualizar os resultados dos primeiros testes representados na Tabela 1.

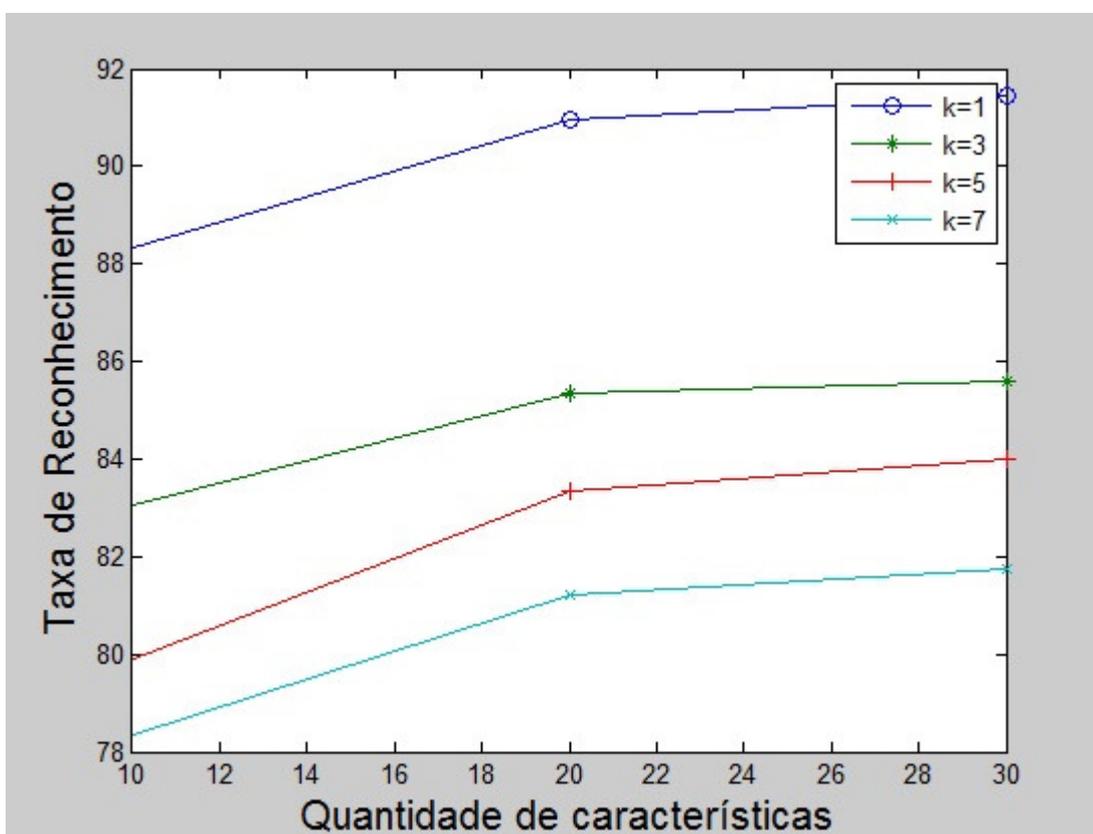


Figura 14. Gráfico da taxa de reconhecimento

Na segunda bateria de testes foram mantidas as mesmas imagens e a forma de realizar os testes também foi idêntica a anterior. Porém, no intuito de comprovar a

propriedade das imagens infravermelhas de independência de iluminação, todas as imagens tiveram seus histogramas equalizados. A Figura 15 retrata as imagens da pessoa 5 normal (esquerda) e com histograma equalizado (direita).



Figura 15. Pessoa 5 sem equalização e com equalização do histograma

Na Figura 16 estão expostos os respectivos histogramas da Figura 13.

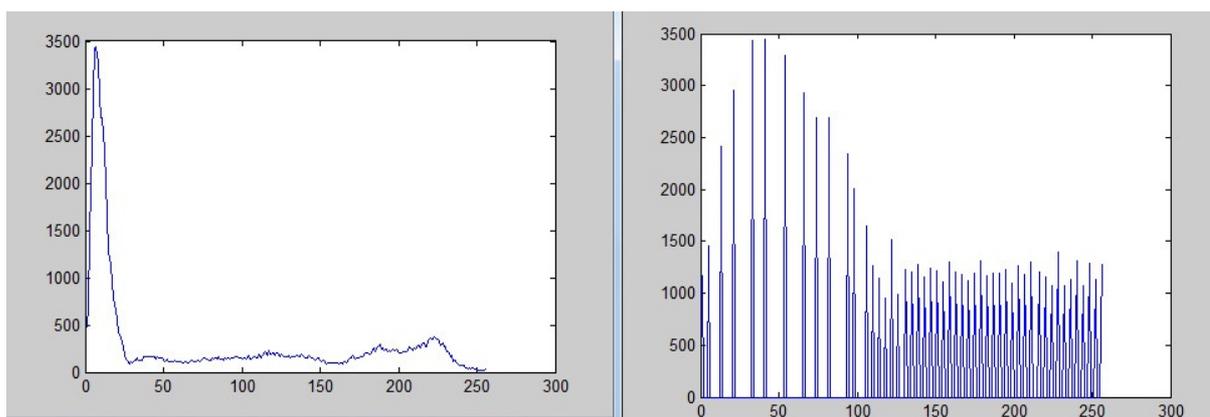


Figura 16. Histograma sem equalização e com equalização da pessoa 5

Na Tabela 2 estão descritos os resultados obtidos para quatro valores diferentes de k com o vetor características variando de 10 a 30, utilizando imagens com histogramas equalizados. É possível notar que, apesar das poucas variações visíveis entre as imagens, foi obtido melhor resultado após equalização dos histogramas das imagens.

Tabela 2. Resultados obtidos equalizando o histograma

Quantidade de Características	Classificação – Taxa de acerto em Porcentagem(%)			
	K = 1	K = 3	K = 5	K = 7
10	91,08	88,21	84,96	83,21
20	93,75	90,58	89,08	87,33
30	94,29	91,21	88,71	86,71

Novamente, com o k do classificador KNN igual a 1 foram obtidos os melhores resultados que podem ser mais facilmente visualizado no gráfico presente na Figura 17. Fazendo a comparação entre os resultados obtidos nos primeiros resultados e estes visualizados na Tabela 2, é possível perceber que novamente as taxas diminuem à medida que se aumenta o valor de k.

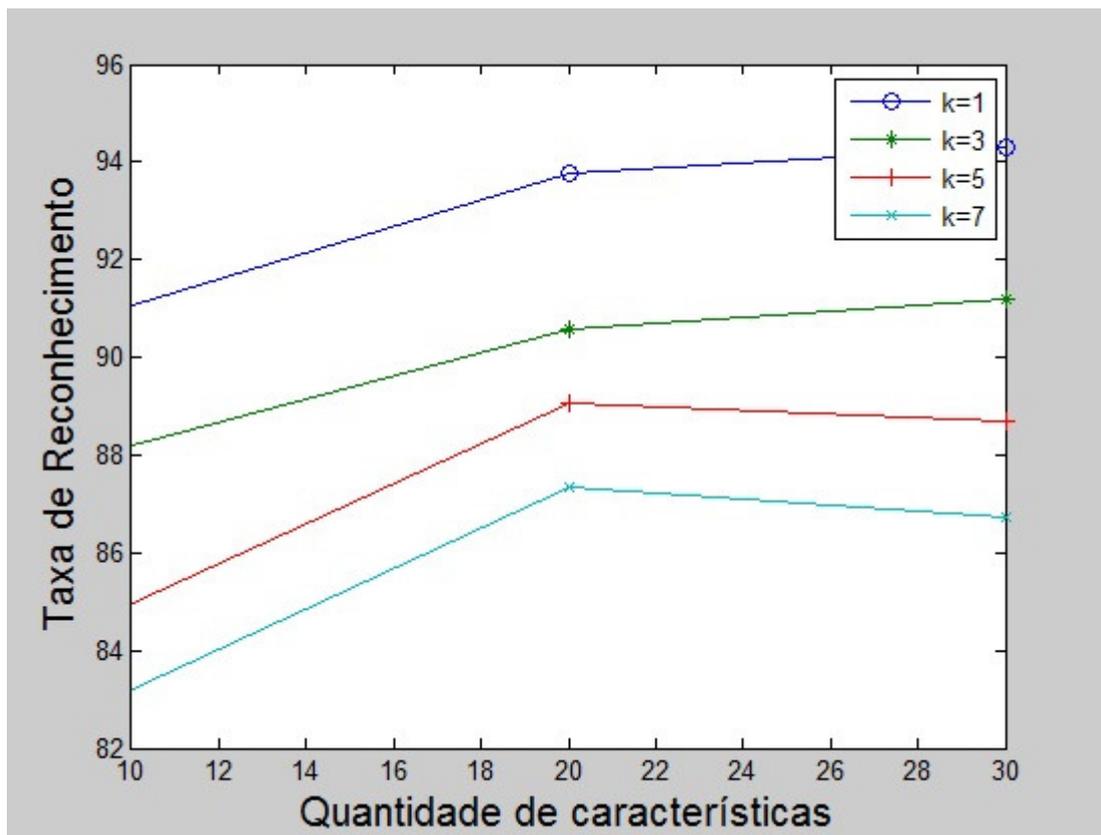


Figura 17. Gráfico obtido equalizando os histogramas

Para analisar a interferência dos disfarces (óculos, chapéu, etc) foi realizada a terceira bateria de testes, esquematizado da seguinte forma: foram separadas imagens sem disfarces de 16 indivíduos diferentes, para compor a base de treinamento. E para teste, foram separadas imagens dos mesmos indivíduos, porém utilizando óculos e/ou cobertura. Na Tabela 3 estão expostos os resultados obtidos usando, na base de treinamento apenas imagens de faces sem disfarces, e na base de testes usando apenas imagens com disfarces.

Tabela 3. Resultados obtidos com disfarces (KNN)

Quantidade de Características	Classificação – Taxa de acerto em Porcentagem(%)			
	K = 1	K = 3	K = 5	K = 7
10	76,56	73,44	70,31	70,31
20	75,00	7500	71,88	71,88
30	76,56	75,00	73,44	71,88

Os dados da Tabela 3 não possuem um referencial comparativo entre as tabelas anteriores, porque os dados foram selecionados manualmente, enquanto nas Tabelas 2 e 3, as imagens foram selecionadas aleatoriamente. Mesmo assim, é possível notar uma considerável queda nos resultados obtidos na terceira bateria de testes. Nesta etapa fica comprovado a interferência que os vidros das lentes dos óculos causam nas imagens de faces infravermelhas. Devido ao fato dos óculos ficarem totalmente escuros, como na Figura 10, o PCA seleciona as lentes como uma das características principais que estão presentes na base de teste, mas não compõe a base de treinamento.

Na Figura 18 fica mais fácil visualizar graficamente, a diminuição da taxa de reconhecimento em relação aos testes anteriores. É possível perceber que a taxa de reconhecimento aumenta quando o valor da quantidade de características é também aumentado. Comprovando a interferência dos óculos nas características principais selecionadas pelo PCA.

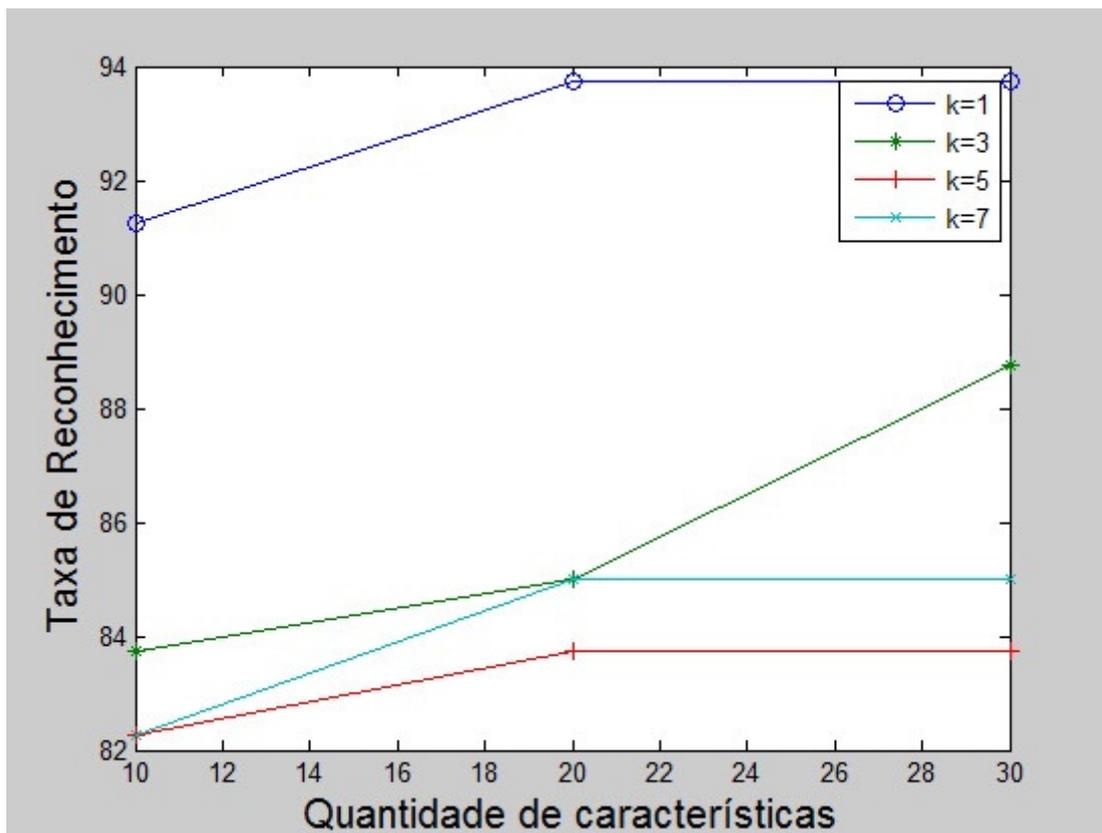


Figura 18. Gráfico da taxa de reconhecimento com disfarces.

Conforme foi relacionado no Capítulo 3 foram usadas duas funções de kernel diferentes para executar as SVMs: polinomial e linear. Os testes realizados com o classificador SVM segue um roteiro diferente do classificador KNN, pois devido às excelentes taxas alcançadas foram feitos testes também nas imagens originais, sem a execução método PCA, ou seja, sem extrair as características mais representativas das faces.

Devido ao fato de não haver extração de características, nos primeiros testes com SVM, a execução desses testes constituiu um período de tempo longo em relação aos demais testes. Na Tabela 4 estão distribuídos os resultados apenas com variação dos parâmetros das funções de kernel.

Tabela 4. Resultados obtidos com SVM sem realizar extração de características

Parâmetro Polinomial (d)	Taxa de acerto em Porcentagem	Parâmetro Função Linear (T)	Taxa de acerto em Porcentagem
1	97,92	1	98,38
2	97,08	3	98,33
3	96,79	5	97,96

Nestes resultados é possível perceber a eficiência das SVMs. Devido as expressivas taxas alcançadas com este classificador e por não haver muita variação nos resultados variando a quantidade de características extraídas, os demais testes com SVM foram realizados com a quantidade de características fixadas em 30.

Os resultados seguintes das SVMs foram obtidos, utilizando PCA, de forma semelhante a primeira bateria de testes do KNN, com 14 imagens de cada indivíduo, em poses diferentes com e sem óculos e/ou usando cobertura. Foram selecionadas aleatoriamente 10 para compor a base de treinamento e 4 para compor a base de testes, e extraída a média aritmética de 30 execução, conforme feito com o KNN. A Tabela 5 expõe os resultados obtidos utilizando nestes experimentos.

Tabela 5. Resultados obtidos com SVM utilizando PCA

Parâmetro Polinomial (d)	Taxa de acerto em Porcentagem	Parâmetro Função Linear (T)	Taxa de acerto em Porcentagem
1	95,17	1	95,17
2	94,46	3	95,17
3	5	5	95,17

Nestes testes foi alcançada a taxa máxima de 95,17% de acerto no reconhecimento das faces infravermelhas, porém com o d maior ou igual a 3 da função de kernel polinomial os resultados não são consideráveis. Isso acontece porque com o grau da função maior ou igual a 3 a complexidade da função se torna superior a necessidade do problema.

Nos testes realizados equalizando o histograma foram utilizadas as mesmas imagens selecionadas para o classificador KNN e os resultados estão descritos na Tabela 6.

Tabela 6. Resultados obtidos com SVM utilizando PCA com equalização

Parâmetro Polinomial (d)	Taxa de acerto em Porcentagem	Parâmetro Função Linear (T)	Taxa de acerto em Porcentagem
1	97,92	1	97,92
2	97,58	3	97,92
3	5	5	97,92

A taxa máxima de acerto de 97,92% obtida equalizando os histogramas das imagens foi idêntica ao resultado obtido com a função de kernel polinomial sem execução do PCA. A vantagem deste resultado em relação ao descrito na Tabela 4 é que, extraindo as características mais visíveis das faces o classificador se torna mais rápido e ocupa menos memória.

Assim como feito no KNN, na terceira bateria de testes com SVM foram separadas imagens sem disfarces de 16 indivíduos diferentes, para compor a base de treinamento. E para teste, foram separadas imagens dos mesmos indivíduos, porém utilizando óculos e/ou cobertura. Na Tabela 7 estão expostos os resultados obtidos usando, na base de treinamento apenas imagens de faces sem disfarces, e na base de testes usando apenas imagens com disfarces.

Tabela 7. Resultados obtidos com disfarces (SVM)

Parâmetro Polinomial (d)	Taxa de acerto em Porcentagem	Parâmetro Função Linear (T)	Taxa de acerto em Porcentagem
1	79,69	1	79,69
2	70,31	3	79,69
3	6,25	5	79,69

É importante salientar que os dados da Tabela 7 não possui um referencial comparativo entre as tabelas anteriores dos resultados de SVM, porque os dados foram selecionados manualmente, enquanto nas Tabelas 4, 5 e 6, as imagens foram selecionadas aleatoriamente. É possível notar que o classificador SVM também é superior ao KNN também quando o indivíduo utiliza disfarces. Contudo a influência dos óculos é determinante para na diminuição dos acertos em reconhecimento de faces utilizando imagens infravermelhas.

Nas Tabelas 8 e 9 é apresentado um resumo enumerando os melhores resultados dos classificadores, após execução do PCA, em duas situações diferentes de teste. A primeira coluna identifica o NN, seguido pelo SVM utilizando a função de kernel polinomial e conseqüentemente o SVM usando a função linear. As taxas são relativas ao melhor resultado dos classificadores em relação ao parâmetro de entrada.

Na Tabela 8 os resultados expostos são referentes aos testes realizados com as imagens na segunda bateria de testes realizadas com o KNN equalizando os histogramas das imagens, assim como foi feito na terceira sequência de testes do SVM.

Tabela 8. Resumo do desempenho dos classificadores

KNN		SVM – Polinomial		SVM – Linear	
Valor de k	Taxa	Valor de d	Taxa (%)	Valor de T	Taxa (%)
1	94,29	1	97,92	1	97,92

Na Tabela 9 estão presentes os resultados obtidos com os classificadores em imagens selecionadas manualmente de indivíduos com disfarces.

Tabela 9. Resumo do desempenho em imagens com disfarces

KNN		SVM – Polinomial		SVM – Linear	
Valor de k	Taxa	Valor de d	Taxa (%)	Valor de T	Taxa (%)
1	76,56	1	79,69	1	79,69

Capítulo 5

Conclusão

O trabalho desenvolvido atendeu aos objetivos propostos, pois obteve-se uma média expressiva de reconhecimento das faces infravermelhas. Sendo mais preciso, foi alcançada uma taxa de acerto de 94,29% utilizando selecionador PCA e classificador por vizinho mais próximo. Utilizando SVM, um classificador mais eficiente baseado em aprendizado estatístico, foi possível chegar a excelência de 97,92% de acerto, utilizando duas funções de kernel diferentes.

Levando em consideração que as imagens de faces infravermelhas foram capturadas em ambientes sem controle de iluminação, através dos resultados obtidos, é possível afirmar que as imagens infravermelhas podem ser utilizadas como uma alternativa para o problema de variação de iluminação.

Além da taxa de acerto, também deve ser analisado o significado da taxa de erro. Observou-se que as lentes dos óculos usados por alguns sujeitos influencia negativamente na taxa. Considerando os erros obtidos neste caso, pode-se afirmar que o uso de óculos prejudica o rendimento de sistemas de reconhecimento de faces baseados em imagens infravermelhas.

O classificador vizinho mais próximo (com k igual a 1) obteve melhor resultado em todos os testes do classificador KNN, enquanto as funções polinomial e linear obtiveram sucesso semelhantes nas SVMs. Em relação ao seletor verifica-se nos testes, de forma geral, o ótimo desempenho oferecido pelo PCA, técnica bastante utilizada para reconhecimento de faces.

Referências

- [1] Wikipedia, “Biometria”, disponível em: <http://pt.wikipedia.org/wiki/Biometria>. Último acesso em 19 de setembro, 2010.
- [2] ASCENSO, J., VALENTIM, J. E PEREIRA, F. **Reconhecimento automático de faces usando informação de textura e de geometria 3D**. 4º Encontro Nacional do Colégio de Engenharia Electrotécnica, Lisboa – Portugal, 1999.
- [3] COSTA, L. R., OBELHEIRO, R. R. E FRAGA, J. S. **Introdução à Biometria**. Livro-texto dos Minicursos, VI Simpósio Brasileiro em Segurança da Informação e de Sistemas Computacionais (SBSeg'2006), p. 103-151. Santos, SP, agosto de 2006.
- [4] MOREIRA, K. S. E PATARO, C. D. M. **Reconhecimento de faces empregando-se, PCA, ICA e RNA - um estudo comparativo**. Universidade Federal de Minas Gerais, 2004.
- [5] KONG, S. G., HEO, J., ABIDI, B. R., PAIK, J. E ABID, M. A. **Recent advances in visual and infrared face recognition - a review**. University of Tennessee, EUA, 2004.
- [6] Turk, M. A. e Pentland, A. P. Face recognition using eigenfaces, **Proceedings of the IEEE Computer Society Conference**, 1991, Cambridge, EUA.
- [7] MATOS, F. M. S. **Reconhecimento de Faces Utilizando a Transformada Cosseno Discreta**. UNIVERSIDADE FEDERAL DA PARAÍBA, João Pessoa, 2008.
- [8] ALMEIDA, O. C. P. **Técnicas de processamento de imagens para localização e reconhecimento de faces**. Universidade de São Paulo, 2006.
- [9] ALMEIDA, F. F. M. **Support Vector Machine**. Universidade Federal de Campina Grande, 2007.

- [10] ARAUJO, G. M. **Algoritmo para Reconhecimento de Características Faciais Baseado em Filtros de Correlação**. Universidade Federal do Rio de Janeiro, 2010.
- [11] RODRIGUES, V. L. **Reconhecimento facial usando SVM**. Universidade Católica do Rio de Janeiro, 2007.
- [12] Wikipedia, “Radiação Infravermelha”, disponível em: http://pt.wikipedia.org/wiki/Radiacao_infravermelha. Último acesso em 27 de setembro, 2010.
- [13] NEVES, S. R. **Algoritmos para Segmentação de Imagens Infravermelhas**. UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, Rio de Janeiro, 2003.
- [14] <http://cienciasaqui.blogspot.com/2010/04/radiacao-infravermelha.html>. Último acesso em 27 de setembro, 2010.
- [15] <http://www.terravic.com/research/facial.htm>. Último acesso em 1 de novembro, 2010.
- [16] Lüersen, A. **Fotografia: a escrita da luz**. UNIVERSIDADE FEDERAL DE SANTA MARIA, Rio Grande do Sul.
- [17] RIBEIRO, I., CHIACHIA, G., MARANA, A. N. Reconhecimento de Faces Utilizando Análise de Componentes Principais e a Transformada Census. **VI Workshop de Visão Computacional**, Presidente Prudente, 2010.
- [18] Wu, S., Fang, Z., Xie, Z. e Liang, W. **Blood Perfusion Models for Infrared Face Recognition**. School of information technology, China, 2008.
- [19] STAN, Z., RUFENG, C., SHENGCAI, L., E LUN, Z. **Illumination Invariant Face Recognition Using Near-Infrared Images**. IEEE Transactions on Pattern Analysis and Machine Intelligence, Abril, 2007.

- [20] XUAN, Z., JOSEF, K., E KIERON, M. **Illumination Invariant Face Recognition: A Survey**. IEEE Transactions on Pattern Analysis and Machine Intelligence, Setembro, 2007.