

4uSecurity

Reconhecimento Facial para Controle de Acesso

Cícero G. O., Arruda ¹, Israel S, Florentino ¹

¹Faculdade de Computação e Informática
Universidade Presbiteriana Mackenzie (UPM)
01.302-907 – São Paulo – SP – Brasil

cicero.arruda@mackenzista.com.br, israel.santos@mackenzie.br

Abstract. *The restriction of access in densely populated areas is a major factor for the success of numerous private or public organizations. In this context, computer vision allows machines to see and extract characteristics present in images captured by different types of sensors, which allow them to recognize, manipulate and process data about the objects that make up the captured image. This article discusses the implementation of a facial recognition system for use in computer vision optimized tools with machine learning*

Resumo. *A restrição de acessos em áreas densamente povoadas é um fator preponderante para o sucesso de inúmeras organizações privadas ou públicas. Neste contexto, a visão computacional possibilita que máquinas enxerguem e extraiam características presentes em imagens capturadas por diferentes tipos de sensores, as quais permitem reconhecer, manipular e processar dados sobre os objetos que compõem a imagem capturada. Neste artigo, aborda-se a implementação de um sistema de reconhecimento facial para uso em ferramentas otimizadas de visão computacional com aprendizagem de máquina.*

1. Introdução

Os avanços tecnológicos levaram a grande concentração social e inúmeras áreas sensíveis possuem frágil segurança de autenticação de pessoal [Magalhães and Santos 2003]. O uso de documentos e senhas como forma de comprovação de identidade ainda é o mais utilizado, porém esses métodos são passivos de fraudes e no caso das senhas, além do risco de ser comprometidas podem ser esquecidas [Pankanti et al. 2000].

Por outro lado, com a presença de novas tecnologias na área de visão computacional, foi possível o desenvolvimento de métodos eficazes e amigáveis de interação com equipamentos substituindo os tradicionais [Yang et al. 2002]. Ainda, a queda nos preços dos equipamentos de tecnologia favorece a exploração de novas análises para a realização de atividades de reconhecimento.

As pesquisas de reconhecimento facial tiveram início a partir de estudos em psico-física e neurofisiologia em meados da década de 70, porém na década seguinte os estudos ficaram praticamente parados sendo retomados na década de 90 com o ressurgimento de classificadores de redes neurais, a disponibilidade de hardware para implementação em tempo real e a carência por aplicativos relacionados à vigilância devido o do tráfico de drogas, atividades relacionadas a terroristas entre outros [Chellappa et al. 1995].

A base principal para pesquisa Biométrica sustenta-se de que não existem pessoas completamente idênticas e por esse motivo é possível desenvolver soluções de comprovação de identidade que substitua documentos, por exemplo. um sistema biométrico é um sistema de reconhecimento de padrões que estabelece a autenticidade de uma característica fisiológica ou comportamental de um usuário [Pankanti et al. 2000].

Os sistemas biométricos baseados em imagens do fundo da retina e em imagens de íris são considerados muito precisos [Pankanti et al. 2000]. Contudo, apesar de conter maior precisão, essas técnicas de reconhecimento são consideradas invasivas devido as condições em que são necessárias para a captura das imagens [Liu and Mark 2001]. Assim, considerado por ser uma aplicação bem sucedida por possuir uma alta taxa de identificação o reconhecimento facial vem recebendo uma atenção significativa nos últimos anos [Barahate and J 2010].

Neste contexto insere-se o presente artigo onde serão implementadas as operações básicas para o desenvolvimento de dois sistemas de reconhecimento de faces, a fim de avaliar qual possui melhor desempenho para uma possível aplicação no controle de acesso de indivíduos.

2. Visão Computacional

Visão Computacional é uma subárea da IA (Inteligência artificial) e tem como objetivo a construção de sistemas de visão artificial possibilitando que máquinas enxerguem e extraiam características presentes em imagens capturadas por diferentes tipos de sensores, as quais permitem reconhecer, manipular e processar dados sobre os objetos que compõem a imagem capturada, com o objetivo de tomar decisões úteis sobre os objetos físicos reais [Shapiro and Stockman 2001].

O reconhecimento de padrões é o estudo de como as máquinas podem observar o ambiente, aprendendo a distinguir padrões de interesse de seus antecedentes e tomando decisões sólidas e razoáveis sobre as categorias dos padrões. Graças aos avanços nas pesquisas foi possível o desenvolvimento de equipamentos computacionais cada vez mais rápidos, que beneficiou muitas áreas [Jain et al. 1999]. Em paralelo ao crescimento está o processamento de imagens, definido como um conjunto de algoritmos que através de fórmulas matemáticas conseguem modificar e/ou alterar imagens sucessivamente [Jain et al. 1999].

O interesse em métodos de processamento de imagens digitais decorre de duas áreas principais de aplicação: melhoria de informação visual para a interpretação humana e o processamento de dados de cenas para percepção automática através de máquinas. Alguns exemplos de aplicações para interpretação humana podem ser encontrados na medicina com os procedimentos computacionais que facilitam a interpretação de imagens de raios X e outras imagens biomédicas, ou ainda o uso pelos geógrafos para estudar padrões de poluição em imagens aéreas [Gonzalez and Woods 2000].

Entretanto, a aplicação para solucionar problemas relacionados à percepção de máquina está focada em extrair informações de uma forma adequada para o processamento computacional [Jain et al. 2007]. Como exemplo, podemos citar o processamento automático de impressões digitais e o reconhecimento facial, que será abordado neste artigo.

3. Reconhecimento Facial

O reconhecimento facial consiste em um método composto de técnicas de análise de características biométricas que pode ser a face, digitais, íris, retina, além de traços comportamentais, como por exemplo, assinaturas e padrão de digitação [Jain et al. 2007]. Atualmente, o Sistema de Reconhecimento é foco de muitas pesquisas no desenvolvimento e aprimoramento de sistemas na área de reconhecimento para autenticação [Jain et al. 2007].

O termo biometria deriva do grego bios (vida) + metron (medida) e, na autenticação, está ligado a utilização de características próprias de um indivíduo para proceder à sua autenticação e/ou identificação [Magalhães and Santos 2003]. Nesse contexto, um sistema biométrico opera através de um banco de imagens de indivíduos conhecidos de onde são retiradas as características para identificar uma nova imagem ainda não processada [Barahate and J 2010].

Os primeiros sistemas de reconhecimento facial utilizavam as características geométricas, tais como a localização e distância entre os pontos, os ângulos, que dessa forma gerava o vetor de características, calculando a distância euclidiana entre os vetores de amostra e a imagem de referência [Jain et al. 2007]. Porém, mesmo com os algoritmos atuais com vetor de características possuindo 22 dimensões, as características geométricas não possuem informações suficientes sobre a face [Brunelli R 1992]. Para os seres humanos, o reconhecimento facial é uma tarefa simples e realizada sem muitos esforços. No entanto, para uma máquina realizar essa tarefa exige uma grande complexibilidade e muito processamento [Jain et al. 2007]. Assim, foram desenvolvidos ao longo dos anos métodos para que a procura por características em uma imagem fique limitado apenas a uma região levando em conta apenas as informações mais importantes [Jain et al. 2007]. Assim, as etapas fundamentais de um sistema de reconhecimento podem ser consideradas: localização, detecção, extração de características da face, bem como o seu reconhecimento [Jain et al. 2007]. Neste artigo serão apresentados métodos de extração de características baseado técnicas de redução de dimensionalidade.

4. Detecção Facial

A detecção facial é uma das primeiras etapas de um sistema de reconhecimento facial, tendo como finalidade identificar todas as regiões da imagem que contêm uma face, não importando sua posição tridimensional, orientação e condições de iluminação [Yang et al. 2002]. Uma das vantagens de localizar a face antes de extrair as características de uma imagem é diminuir o tempo e processamento do sistema. Isso porque muitos dos algoritmos de reconhecimento utilizam toda a imagem para análise de características, desta forma, já com a localização da face a procura fica apenas em uma determinada região da imagem [Jain et al. 2007].

A detecção de face é uma tarefa difícil, pois as faces não são rígidas e possui diferentes tamanhos, formas, cor e textura, sendo necessário algoritmos robustos e eficientes, conforme apresenta-se na figura 1. Ainda, existem outros desafios que precisam ser enfrentados, tais como: **Pose**, que de acordo com a posição em que a câmera captura a imagem, ela pode ter variações ocultando alguma característica da face, como olhos, nariz e boca; **Presença de Elementos Estruturais**, tais como como barba, bigode, e óculos, que podem alterar as características da face; **Expressão facial**, que influencia diretamente



Figura 1. Faces detectadas em um grupo de pessoas

na aparência da imagem de face; e a **Ocultação**, que ocorrem quando a imagem aparecer, parcialmente ou totalmente sobrepostas, por objetos ou até mesmo por outras faces [Yang et al. 2002].

Os principais métodos utilizados para a detecção de face são: **Métodos Baseados em Conhecimento**[Yang et al. 2002], que se Utiliza de atributos geométricos da face como regras estabelecidas, considerando olhos, nariz e boca como características válidas de uma face humana; **Métodos Baseados em Características Invariantes**[Yang et al. 2002], que busca características invariantes da face independente da sua orientação, tais como cor da pele e a textura da face. Neste método são utilizados segmentação de pele e modelagem estatística da textura; **Métodos Baseados em Templates**[Yang et al. 2002], que realiza a procura de objetos na imagem com base no seu próprio molde que foi formado por um conjunto de curvas com características geométricas básicas, como círculos, quadrados ou triângulos; **Métodos Baseados na Aparência**[Yang et al. 2002], quando o sistema não possui conhecimento sobre o objeto a ser detectado. Nele é utilizado as técnicas de aprendizagem de máquina onde a base de conhecimento é aprendida a partir de um conjunto de amostras dos objetos a serem reconhecidos. As Redes Neurais, Modelos Ocultos de Markov, e o método Eigenfaces que será utilizado nesse projeto são exemplos dessa abordagem.

Um método muito conhecido por ser rápido, permitindo seu uso em aplicações de tempo real, e com uma alta taxa de detecção de face foi proposto por Jones [Viola and Jones 2001]. Trata-se de uma nova representação da imagem, denominada imagem integral, seguido por um classificador simples e eficiente que utiliza o algoritmo de aprendizado adaboost. Esse classificador pode ser treinado para localizar qualquer objeto que apresente um padrão. Trata-se de um classificador em cascata baseado em Harr-like features. As Haar-like são utilizadas para representar transições entre regiões mais claras e escuras. São características simples extraídas da imagem com o objetivo de representá-la de forma mais compacta. Um exemplo da sua utilização é a representação da região dos olhos, pois comparado com a das bochechas ela é uma região mais escura [Viola and Jones 2001]. A figura 2 ilustra-se a função em cascata treinada por várias imagens negativas e positivas e, em seguida, gera-se um arquivo com as informações a serem utilizadas para a detecção de faces em outras imagens.

5. Algoritmos

Um dos principais desafios no processo de reconhecimento é trabalhar com a dimensionalidade das imagens de face devido seu tamanho. Em visão computacional, a dimen-

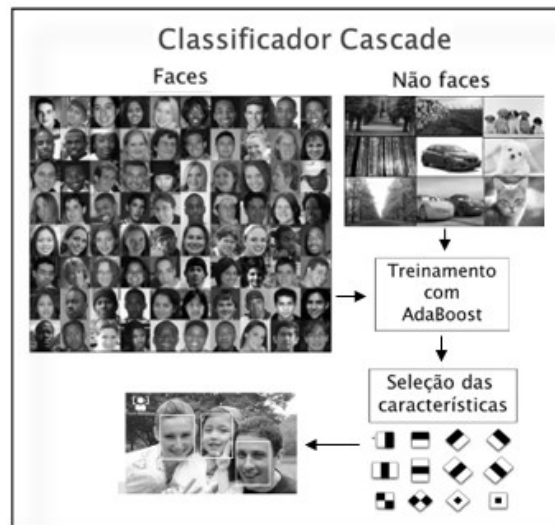


Figura 2. Treinamento do Classificador para reconhecimento de faces

sionalidade é atribuída ao número de características de uma representação de padrões, representando assim a dimensão do espaço de características (n). Exemplo disso são as imagens bidimensionais $i \times j$, que em escala de cinza, abrangem $n = i \times j$ dimensões vectoriais, resultando em uma imagem de tamanho 100×100 , igual a um espaço de 10:000 dimensões. Além disso, no processo de reconhecimento facial, em um espaço de alta dimensionalidade apenas as dimensões que apresentam alguma variância são as que mais influenciam nas diferenças entre as imagens, pois as imagens de faces não se encontram distribuídas de forma aleatória.

Conforme [Jain et al. 1999], quando o espaço de característica contém somente as características mais importantes para o processo de classificação, o classificador ficará mais rápido além de ocupar menos memória. Por esse motivo, com uma dimensionalidade menor, há um ganho no custo de medição e precisão do classificador

5.1. Eigenfaces

O método de Eigenfaces [Turk and Pentland 1991] é baseado na transformada de Karhunen-Loeve (KLT) e PCA (Principal Component Analysis), que tem como objetivo analisar os dados visando reduzir a dimensionalidade através de uma análise estatística que se baseia na redundância e na variância existentes nos dados [Barahate and J 2010]. Logo, a técnica PCA trabalha com a redução da dimensionalidade com foco na variação das imagens, para esse método a iluminação é um componente importante e pode destacar outras características, conforme se apresenta na figura 3.




Figura 3. As faces são decompostas em uma série de componentes principais - Eigenfaces

Conforme [Turk and Pentland 1991] as imagens de faces não se encontram distribuídas de forma aleatória em um espaço de alta dimensionalidade, e por esse motivo, podem ser descritas em um espaço de dimensão menor.

A abordagem transforma faces em um pequeno conjunto de características essenciais, chamadas autofaces, que são os principais componentes do conjunto inicial de imagens de aprendizado (conjunto de treinamento), que buscam encontrar um espaço vetorial que melhor descreve um objeto utilizando poucas dimensões [Slavković and Jevtić 2012]. É considerado umas das melhores transformações lineares e um dos métodos mais utilizados pela comunidade de reconhecimento de padrões [Slavković and Jevtić 2012].

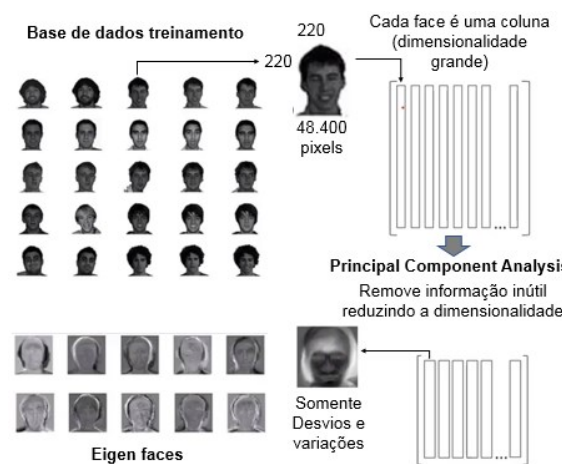


Figura 4. Eigenface

O algoritmo *Transformada Discreta de Karhunen-Luève* (KLT) recebe o nome em homenagem a Kari Karhunen, Michel Loève e Harold Hotelling, responsáveis por transformar variáveis discretas em coeficientes não correlacionadas e denominar como Método dos Componentes Principais (PCA).

5.2. Fisherfaces

O método fisherface utiliza a técnica de Análise de Discriminante Linear (LDA), analisando um conjunto de imagens de treinamento rotulado e formado por diversas classes que representam a identidade de cada sujeito com base em conjunto previamente conhecido. Tem como finalidade identificar em uma imagem a qual classe ela pertence não interessado na maior variação, mas com o objetivo de maximizar a separação entre classes [Yang 2002]. O método se utiliza da informação do conjunto de treinamento que esta rotulado, e assim, busca maximizar a variância entre as classes e minimizar a variância dentro da classe. Assim, quanto mais diferente for uma pessoa da outra, mais distantes deverão estar suas projeções, e quanto mais parecidas, mais próximas estarão suas projeções, garantindo de forma mais eficaz a separação entre classes em um conjunto de imagens [Belhumeur and J 1997].

Uma das principais proposta do método, além de trabalhar na redução da dimensionalidade, é sua baixa sensibilidade a iluminação das imagens e expressão facial. Seu nome se dá por utilizar o discriminante linear de Fisher (FLD). Trata-se de um método que otimiza o espalhamento da projeção espacial a fim de encontrar o classificador mais confiável [Belhumeur and J 1997].

As fisherfaces são as imagens de características onde há variações de aparência presentes nas imagens, como por exemplo variações de luminosidade, poses e expressões faciais [Yang 2002].

A base de conhecimento de um Sistemas de Reconhecimento pode ser baseada em regras, incrementado diretamente no código ou a partir de um conjunto de amostras, conhecida como técnica de aprendizado de máquina. Tanto o Eigenfaces como também o Fisherfaces, são métodos baseados em algoritmos de aprendizado e por esse motivo, para avaliar o desempenho dos métodos de detecção dependem fortemente de um conjunto de treinamento de uma base de dados adequada [Yang et al. 2002].

6. Resultados

A figura 5 apresenta as etapas de reconhecimento utilizadas neste trabalho e inicia-se com a coleta das imagens de um banco de dados de imagens padronizado e são armazenadas em um arquivo local seguido pela detecção da face. Já com a localização da face, foi realizado a segmentação, separando a face do restante da imagem. Na etapa seguinte é chamado o método para realizar o treinamento com as imagens do banco e o reconhecimento facial.

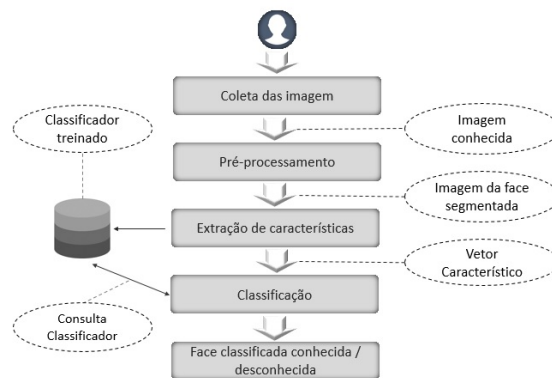


Figura 5. Etapas do Sistema de Reconhecimento Facial

6.1. Ferramentas

Foi utilizada para implementação do projeto a linguagem Python na versão 3.8.2. Para a implementação das ferramentas foi aplicado as bibliotecas Numpy. Para o tratamento de vetores e operações matemáticas, foi utilizada a biblioteca PIL. Para uso de imagens e para as funções de processamento de imagem com foco em aplicações de tempo real foi utilizada a biblioteca gráfica OpenCV.

6.2. Coleta das imagens

As imagens para o treinamento e testes foram obtidas da base de dados Yale Face, muito utilizados por pesquisadores da área de reconhecimento facial por possuir inumeras variações de faces, como luz, uso de óculos e expressões diversas.



Figura 6. Modelo do banco de dados

A base utilizada é formada por dois conjuntos de imagens devidamente etiquetados (indivíduo conhecido): a base de treinamento com um total de 135 imagens, dividido em 15 classes (9 fotos por sujeitos) e outra para testes com um total de 30 imagens (2 fotos por sujeitos) dos mesmos sujeitos da base de treinamento, porém com variações e poses diferentes.

Banco de Dados	Imagens	Classes	Características
Yale Face - Treinamento	135	15	Condição de iluminação distinta; variação de expressão;
Yale Face - Teste	30	15	

Figura 7. Quadro com a formação das classes do banco de dados utilizado

6.3. Detecção Facial

O algoritmo Haar Cascade, foi utilizado para a detecção da região facial nas imagens do treinamento e de testes. Para este processo, o arquivo haarcascade-frontalface-default.xml (treinado) foi escolhido já que apresenta um alto índice de detecção de faces do banco de imagens utilizados.

6.4. Treinamento e Reconhecimento

Os algoritmos Eigenfaces com o uso da técnica PCA [Turk and Pentland 1991] e Fisherfaces com o uso da técnica LDA [Belhumeur and J 1997] foram responsáveis pelo treinamento e classificação das imagens.

Na fase de treinamento foram realizados vários testes com diferentes parâmetros para se chegar a um valor adequado. Os parâmetros utilizados: Num components (Número de componentes principais – quantidade eigenfaces/fisherfaces gerado através do método PCA/LDA) e thresholds (Limite de confiança / distância vizinho mais próximo). As faces detectadas com valor de threshold maior que o especificado foram consideradas desconhecidas pelos algoritmos.

A etapa de treinamento é executada apenas uma vez ou quando um novo sujeito é adicionado ao banco. Após o classificador ser treinado é salvo em arquivo para ser utilizado na etapa de reconhecimento.

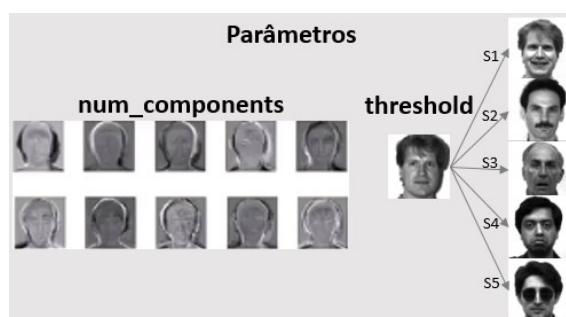


Figura 8. Ilustração dos parâmetros num components e threshold

Após a execução das etapas de detecção de faces e a extração de características, onde foram obtidos os componentes principais que mais retratam o banco de imagens usado no treinamento, foi então realizado o processo de reconhecimento, utilizando uma imagem de face já segmentada no espaço facial do banco utilizado para testes, dos mesmos indivíduos do treinamento, porém com variações diferentes e com a finalidade de encontrar qual face do conjunto de treinamento ela mais se assemelha.

O desempenho dos métodos foi levado em consideração os tempos de cada um deles. Por esse motivo, importante ressaltar que o ambiente utilizado para a aplicação e avaliação foi através de um computador pessoal.

A figura 9 revela os tempos de treinamento e reconhecimento dos algoritmos eigenfaces e fisherfaces, utilizando o conjunto de treinamento com 130 imagens e de teste com 30 imagens.

Método	Treinamento 130	Reconhecimento 30
Eigenfaces	119	86
Fisherfaces	26	41

Figura 9. Tempo médio de processamento dos métodos, em segundos

As medidas utilizadas para a avaliação de cada método com diferentes configurações (número de componentes e threshold) foi o percentual de acerto (taxa de acertos) e a confiança (limite de confiança).

$$\text{Percentual acerto} = ((\text{total acertos} / 30) * 100)$$

$$\text{Total confiança} = (\text{total confiança} / \text{total de acertos})$$

Eigenfaces					
Parâmetros		Resultado			
n_comp	threshold	Acertos	Erros	% Acertos	Confiança
135	1.797	22	8	73,33	5.444
20	8.000	21	9	70,00	3033
30	8.000	20	10	66,67	3189
10	8.000	19	11	63,33	2011
20	7.000	19	11	63,33	2546
40	8.000	18	12	60,00	2.976
50	8.000	16	14	53,33	2556
50	1.800	7	23	23,33	748
100	2.000	5	25	16,67	472
120	1.500	4	26	13,33	238

Figura 10. Resultados Algoritmo Eigenfaces

Fisherfaces					
Parâmetros		Resultado			
n_comp	threshold	Acertos	Erros	% Acertos	Confiança
4	1.800	26	4	86,67	574
4	1.850	26	4	86,67	574
4	1900	26	4	86,67	574
4	1.700	25	5	83,33	526
4	1.750	25	5	83,33	526
3	2.000	24	6	80,00	445
5	1.800	24	6	80,00	551
3	1.800	24	6	80,00	445
14	1.797	22	8	73,33	1.797
10	2.000	21	9	70,00	697

Figura 11. Resultados Algoritmo Fisherfaces

7. Conclusão

Este artigo apresentou uma proposta de baixo custo para a implementação de um sistema de reconhecimento de faces em ambiente controlado. Foi utilizado técnicas de reconhecimento de padrões associadas ao reconhecimento de face, métodos que trabalham com a redução de dimensionalidade em busca de seleção de características.

Para medir a performance foram utilizados os bancos de Yale Faces com imagens de face com grandes variações de iluminação.

O método fisherfaces apresentou melhores resultados nas duas medidas da avaliação. Isso demonstra que além de ter um maior número de acertos, há uma certeza maior com relação a esses números, considerando maior confiabilidade.

O fato de as imagens de face possuir grandes variações de iluminação, evidenciou uma fragilidade do método eigenfaces que foca nas características que distingue um indivíduo do outro (face do indivíduo como um todo) e por esse motivo considera a iluminação um componente importante podendo descartar outras características das face. Já o método fisherfaces não está interessado na maior variação, mas sim em maximizar a separação entre as classes realizando a extração das características separadamente e com isso a iluminação de uma face não altera as outras faces.

Referências

- Barahate, S. R. and J, S. (2010). Face recognition using pca based algorithm and neural network. *Proceedings of the International Conference and Workshop on Emerging Trends in Technology*, pages 249–252.
- Belhumeur, Peter N and, H. J. P. and J, K. D. (1997). Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on pattern analysis and machine intelligence*, 19(7):711–720.
- Brunelli R, P. T. (1992). Face recognition through geometrical features. *European Conference on Computer Vision*, pages 792—800.
- Chellappa, R., Wilson, C. L., and Sirohey, S. (1995). Human and machine recognition of faces: A survey. *ieeexplore.ieee.org*, 83(5):705–740.
- Gonzalez, R. C. and Woods, R. E. (2000). *Processamento de imagens digitais*. Edgard Blucher.
- Jain, A. K., Duin, R. P. W., and J, M. (1999). Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (5):1–105.
- Jain, A. K., Flynn, P., and Ross, A. A. (2007). *Handbook of biometrics*.
- Liu, S. and Mark, S. (2001). A practical guide to biometric security technology. *IT Professional*, pages 27–32.
- Magalhães, P. S. and Santos, H. D. (2003). *Biometria e autenticação*. Actas da 4ª Conferência da Associação Portuguesa de Sistemas de Informação, 4th edition.
- Pankanti, S., Bolle, R. M., and Jain, A. (2000). Biometrics: The future of identification. *ieeexplore.ieee.org*, (5):46–49.
- Shapiro, L. and Stockman, G. C. (2001). *Computer vision*. Prentice Hall.
- Slavković, M. and Jevtić, D. (2012). Face recognition using eigenface approach. *Serbian Journal of electrical engineering*, 9(1):121–130.
- Turk, M. A. and Pentland, A. P. (1991). Face recognition using eigenfaces. *Proceedings. 1991 IEEE computer society conference on computer vision and pattern recognition*, pages 586–591.

- Viola, P. and Jones, M. J. (2001). Robust real-time face detection. *International Journal of Computer Vision*, (5):137—154.
- Yang, M.-H. (2002). Kernel eigenfaces vs. kernel fisherfaces: Face recognition using kernel methods. In *Fgr*, volume 2, page 215.
- Yang, M. H., Kriegman, D. J., and Ahuja, N. (2002). Detecting faces in images: A survey. *ieeexplore.ieee.org*, 24(1):34–58.