

Universidade Católica Dom Bosco

Curso de Bacharelado em Engenharia de Computação

Comparação entre Técnicas de Reconhecimento de Faces para Controle de Acesso a Computadores

Vinícius Assis Saueia da Silva

Prof. Orientador: Dr. Hemerson Pistori

Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação.

UCDB - Campo Grande - MS - Novembro/2008

a todos aqueles que fizeram parte, de alguma forma, nesses 5 anos de história, em espcial a minha família.

Agradecimentos

Agradeço primeiramente a Deus, foi Ele meu maior companheiro nos momentos de dificuldade, nos momentos de dúvida, alegria, derrota, vitória, tristeza, paz, conflitos. Foi Ele quem me ajudou a buscar a sabedoria, enfrentar os diversos obstáculos que pareciam intransponíveis. Em alguns momentos de pouca fé eu tentei fugir Dele, mas Ele mais uma vez me mostrou sua força e hoje não vivo longe Dele. Obrigado Senhor.

Agradeço também a todos os que me ajudaram nessa caminhada desafiante e muito recompensadora. Agradeço especialmente aos meus pais, irmã e outros familiares que foram primordiais em diversos momentos ao longo de toda minha vida. Agradeço aos professores que sempre me foram úteis e muitas vezes mais que simplesmente educadores. Agradeço meus amigos e companheiros de classe que são fontes de inspiração, bons conselhos, exemplos e muito responsáveis por momentos agradáveis de laser ou em momentos de se manter a seriedade.

Agradeço também ao meu computador portátil por ter suportado a alta temperatura de Campo Grande nos dias de calor intenso que precisei deixá-lo ligado por mais de 15 horas seguidas.

Resumo

Esse trabalho apresenta um estudo realizado de técnicas de reconhecimento facial baseadas em Análise Discriminante de Fisher e Análise de Componentes Principais. O objetivo desse projeto foi construir um sistema de controle de acesso a computadores utilizando técnicas de reconhecimento de faces. Para isso foram estudadas algumas técnicas bastante citadas na literatura, como Eigenfaces e Fisherfaces. As técnicas de reconhecimento nesse trabalho foram aplicadas pixel a pixel, portanto não foram utilizadas técnicas auxiliares para extração de atributos. São descritos os passos seguidos para o desenvolvimento do projeto, são apresentadas em detalhes as tecnologias utilizadas e o modelo seguido para implementação das técnicas escolhidas. São apresentados os experimentos realizados para redimensionalização de imagens que apresentaram que a redução da resolução da imagem pode não interferir significativamente na classificação automática, pois os resultados obtidos demonstraram que mesmo após uma redução de 97% do número original de pixels, a taxa de classificação se manteve acima de 99% para a maioria dos classificadores testados. É apresentado também o experimento realizado para se determinar qual a taxa de redução que deve ser realizada pela técnica Eigenfaces antes da aplicação da técnica Fisherfaces que obteve como resultado uma taxa de 35% de redução inicial e manteve as taxas de classificação em níveis satisfatórios, acima de 98%. São detalhados também os experimentos que comparam as taxas de classificações corretas obtidas entre as técnicas escolhidas e as análises dos resultados atingidos. Por fim, são apresentadas as conclusões obtidas e discutidas de propostas para trabalhos futuros.

Conteúdo

1	Inti	rodução	9
2	Fun	ndamentação Teórica	12
	2.1	Processamento Digital de Imagens	12
		2.1.1 Imagem	12
		2.1.2 Cor	13
	2.2	Conceitos de Álgebra	14
		2.2.1 Matriz	15
		2.2.2 Determinante	16
		2.2.3 Operações com Matrizes	16
		2.2.4 Matriz Inversa	18
		2.2.5 Auto-vetores e Auto-valores	19
	2.3	Aprendizagem Automática	19
		2.3.1 Aprendizagem supervisionada e não-supervisionada	19
		2.3.2 Métodos de validação	20
3	Rec	conhecimento de Faces	21
•	3.1	Eigenfaces	21
	3.2	Fisherfaces	23
4	Tra	balhos Correlatos	26
	4.1	Reconhecimento de Faces em Sistemas	26
	4.2	Análise de Componentes Principais e Discriminate de Fisher	
		em Aplicações	27
5	De	esenvolvimento	28
6	-	perimentos, Resultados e Análise	32
	6.1	Experimento 1 - Verificar influência da resolução de imagens	
		digitais de face na classificação automática	34
		6 1 1 Descrição do experimento	34

Conteúdo UCDB

		6.1.2 Resultados e análises	35
	6.2	Experimento 2 - Confirmação dos resultados obtidos com a	
		resolução escolhida	37
		6.2.1 Descrição do experimento	37
		6.2.2 Resultados e análises	37
	6.3	Experimento 3 - Encontrar taxa de redução a ser utilizada na	
		técnica Eigenfaces para a aplicação da técnica Fisherfaces	38
		6.3.1 Descrição do experimento	38
		6.3.2 Resultados e análises	39
	6.4	Experimento 4 - Comparação entre as taxas de classificação	
		das técnicas escolhidas	39
		6.4.1 Descrição do experimento	39
	6.5	Experimento 5 - Encontrar taxa de redução inicial para a apli-	
		cação da técnica Fisherfaces no conjunto de faces masculinas .	41
		6.5.1 Descrição do experimento	
		6.5.2 Resultados e análises	41
7	Co	nclusões e Trabalhos Futuros	43
\mathbf{A}	Tab	elas de Resultados	45
$\mathbf{R}\epsilon$	eferê	ncias Bibliográficas	54

Lista de Figuras

2.1	Exemplo de uma imagem colorida submetida a processamentos	
	digitais	13
2.2	Espaço de cores HSB	14
2.3	Espaço de cores RGB	14
3.1	Comparação entre projeções realizadas por PCA e FLD (Hespanha e Kriegman em [BHK97])	24
5.1	Diagrama de classes que representa o modelo implementado	29
5.2	Trecho de código da função que faz a redução de atributos a partir de um arquivo .arff de entrada	30
5.3	Trecho de código que implementa os cálculos da técnica Eigen-	
	faces.	30
5.4	Trecho de código que implementa os cálculos da técnica	
	$Fisherfaces. \dots \dots$	31
6.1	Exemplos de imagens de faces masculinas e femininas pre-	2.2
	sentes no banco de imagens utilizado	33
6.2	Resultados das classificações após reduções de resolução com	
	imagens de faces de mulheres	35
6.3	Resultados das classificações após reduções de resolução com	
	imagens de faces de homens	36
6.4	Resultados das classificações após reduções de resolução com	
	imagens de faces de ambos os sexos	36

Lista de Tabelas

A.1	Resultados do Experimento 1 para imagens de faces de mulheres.	45
A.2	Resultados do Experimento 1 para imagens de faces de homens.	46
A.3	Resultados do Experimento 1 para imagens de faces de homens	
	e mulheres	46
A.4	Resultados do Experimento 2 para imagens de faces de mulheres.	47
A.5	Resultados do Experimento 2 para imagens de faces de homens.	47
A.6	Resultados do Experimento 2 para imagens de faces de homens	
	e mulheres	47
A.7	Resultados do Experimento 3 para $N-c$ e $c-1$	48
A.8	Resultados do Experimento 3 variando a redução com Eigen-	
	faces e reduzindo para $c-1$ com $Fisherfaces$	48
A.9	Resultados do Experimento 4 com redução de atributos via	
	Eigenfaces no conjunto de mulheres	49
A.10	Resultados do Experimento 4 com redução de atributos via	
	Eigenfaces no conjunto misto	50
A.11	Resultados do Experimento 4 com redução de atributos via	
	Eigenfaces no conjunto de homens	51
A.12	Resultados do Experimento 4 com redução de atributos via	
	Fisherfaces no conjunto feminino	52
A.13	Resultados do Experimento 4 com redução de atributos via	
	Fisherfaces no conjunto masculino	52
A.14	Resultados do Experimento 4 com redução de atributos via	
	Fisherfaces no conjunto misto	53
A 15	Resultados do Experimento 5	53

Capítulo 1

Introdução

Hoje, é comum fazer o monitoramento de segurança em diversos locais públicos ou privados. Vários equipamentos podem ser utilizados para fazer o monitoramento, como sensores de presença, câmeras e computadores para registros de acessos. Em situações simples, onde não se precisa ter detalhes do usuário, são usados dispositivos mais simples, sensores de presença, por exemplo, como em um sistema de disparo de alarme. Entretanto, existem dispositivos que permitem fazer um monitoramento mais completo, como as câmeras, que normalmente são utilizadas em situações onde precisa-se controlar visualmente o ambiente.

As câmeras podem ser utilizadas de diversas maneiras em sistemas de segurança, pode-se utilizá-las como filmadoras em tempo real, onde uma pessoa faz o monitoramento ou pode-se também armazenar as imagens capturadas, deixando-as disponíveis para eventuais análises. Porém, armazenar muitas imagens requer muito espaço em disco, então opta-se por reduzir a qualidade da imagem. Entretanto, imagens com baixas resoluções e que são capturadas em movimento são difíceis de serem analisadas por seres humanos, o que pode dificultar análises posteriores, podendo atrapalhar o reconhecimento de faces, por exemplo.

Fazer o reconhecimento de faces automático pode resolver o problema de erros humanos eventualmente ocorridos. Através de técnicas de visão computacional, processamento digital de imagens e aprendizagem automática é possível desenvolver um programa computacional capaz de fazer o reconhecimento de faces em imagens. No entanto, fazer o reconhecimento de faces em ambientes reais não é uma tarefa trivial pois pode ocorrer variação de iluminação no ambiente, variação na posição da face ou ainda podem aparecer distorções ou rotações da face na imagem.

Neste trabalho foram estudadas algumas das técnicas mais citadas na literatura para se fazer reconhecimentos de faces. As técnicas escolhidas foram:

Eigenfaces e Fisherfaces. Os objetivos desse trabalho são: criar um ambiente de uso restrito a usuários cadastrados em um banco de imagens, em que a imagem da face do usuário será a chave de acesso ao sistema e comparar as técnicas de reconhecimento de faces escolhidas através de testes executados com bancos de imanges. Dessa maneira, pode-se criar um ambiente que simule controle de acesso a lugares restritos e pode-se ainda esetender o uso para sistemas de segurança pública, que é uma área que vem sendo bastante pesquisada, como mostra Seow et al.[SGVA04]. As técnicas escolhidas serão aplicadas diretamente nos pixels da imagem, isto é, não serão utilizadas técnicas de extração de atributos adicionais.

Para o desenvolvimento desse projeto utilizou-se a plataforma SIGUS¹, que é uma biblioteca que apresenta diversos algoritmos de visão computacional, processamento de imagens e aprendizagem automática prontos para serem usados na construção de novos programas, todos os códigos da biblioteca SIGUS são livres para modificação e distribuição e escritos na linguagem de programação Java. Foram utilizadas também algumas ferramentas Java para ajudar no desenvolvimento desse projeto, como a ferramenta ImageJ² para manipulação de imagens, a ferramenta Weka³ que oferece diversas implementações e ambientes fáceis para realização de experimentos com algoritmos de aprendizagem automática e a biblioteca Jama⁴ que disponibiliza diversas implementações algébricas e matemáticas. Todas as ferramentas utilizadas na implementação desse projeto são escritas na linguagem de programação Java.

As imagens digitais normalmente utilizadas em bancos de imagens de faces possuem alta resolução e isso, conseqüentemente, faz com que as imagens tenham um grande número de pixels. Os atributos utilizados nesse projeto são os próprios pixels da imagem e como as técnicas escolhidas fazem cálculos algébricos que utilizam muitos recursos computacionais, foram realizados experimentos para verificação da conseqüência da redução da resolução de imagens para algoritmos de aprendizagem automática. Foram realizados experimentos também para determinar melhor as formas de utilização das técnicas escolhidas. E por fim, foram realizados testes para comparar as taxas de acertos na classificação utilizando as técnicas de reconhecimento de faces escolhidas.

O texto desse trabalho está dividido em 7 partes. O capítulo 2 apresenta

¹Plataforma de Apoio ao Desenvolvimento de Sistemas para Inclusão Digital de Pessoas com Necessidades Especiais. Informações em http://www.gpec.ucdb.br/sigus

² Website do projeto: http://rsbweb.nih.gov/ij/

³Mais informações sobre a ferramentas disponíveis em http://www.cs.waikato.ac.nz/ml/weka/

⁴Detalhes da biblioteca em http://math.nist.gov/javanumerics/jama/

alguns dos principais conceitos utilizados em técnicas de reconhecimento de faces mais utilizadas atualmente, como matrizes, auto-valores e auto-vetores. No capítulo 3 são detalhadas as técnicas de reconhecimento de faces estudadas nesse trabalho. No capítulo 4 são apresentados alguns trabalhos relacionados. O desenvolvimento do trabalho é apresentado no capítulo 5. No capítulo 6 são detalhados os experimentos realizados e são feitas as análises dos resultados obtidos. E por fim, o capítulo 7 apresenta as conclusões e propostas para trabalhos futuros.

Capítulo 2

Fundamentação Teórica

2.1 Processamento Digital de Imagens

O Processamento Digital de imagens é a área do conhecimento que tem como objetivo analisar e manipular imagens digitais para obtenção de melhorias estruturais sob a imagem, através da extração de informações relevantes para determinados problemas, para analistas humanos ou para ajudar em processamentos posteriores. Técnicas de processamento digital de imagens podem ser utilizadas em diversas áreas como Meteorologia, Medicina, Agricultura e outras. [GW01]

Existem diversos tipos de processamentos que podem ser realizados sobre uma imagem, como operações morfológicas, binarização, transformações dos espaços de cores, entre outros. A Figura 2.1 mostra uma imagem colorida capturada por uma webcam submetida a alguns processamentos digitais.

2.1.1 Imagem

Uma imagem é comumente representada como uma função f(x,y) bidimensinal, na qual os valores assumidos pela função representam a quantidade de energia captada por algum dispositivo de captura de imagens. Imagens podem ser analógicas ou digitais, entretanto para que possam passar por processamentos digitais é necessário que as imagens estejam digitalizadas, chamadas também de discretizadas. A fotografia é um exemplo bastante comum de representação de imagem.

Uma imagem discretizada é uma malha de dimensão $n \times m$ com deslocamento d_x de 0 a n-1 e d_y de 0 a m-1. Os deslocamentos (d_x, d_y) são os pixels, os quais indicam a cor em determinado ponto da imagem. O pixel é o menor elemento da imagem e possui informação geralmente muito importante para o processamento digital e outras aplicações como reconhecimento

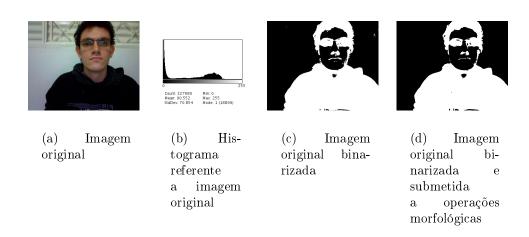


Figura 2.1: Exemplo de uma imagem colorida submetida a processamentos digitais.

de padrões e visão computacional.

2.1.2 Cor

As informações de cores são muito importantes em uma imagem, é através dela que pode-se perceber determinados detalhes. A visão humana é construída através das cores, então ao utilizar-se as informações de cores no processamento de imagens as técnicas tornam-se mais fáceis de serem visualizadas por analistas [FP03].

Existem diversos modelos que descrevem a formação das cores, esses modelos são conhecidos como espaços de cores. A seguir são detalhados alguns dos espaços de cores mais utilizados para se fazer o processamento de imagens.

Modelo HSB

O HSB (*Hue Saturation Brightness*) é um espaço de cores tridimensional com formato de cone, onde o H é a matiz da cor, ou seja, é o formato de onda que caracteriza a cor, o S está relacionado com o grau de saturação, que é o grau de pureza da cor e o B é o brilho, ou seja, a luminosidade da cor. Esse espaço HSB é bastante utilizado em algoritmos de visão computacional por separar a componente relacionada ao brilho, isso é conveniente pois torna mais fácil de retirar a influência indesejada da variação de iluminação nos ambientes que ocasionalmente podem ocorrer. A Figura 2.2 apresenta a representação do espaço de cores HSB.

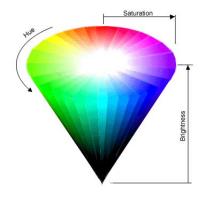


Figura 2.2: Espaço de cores HSB

Modelo RGB

O RGB (Red Green Blue) é um espaço de cores tridimensional cúbico, onde a componente R está relacionada com a porção de vermelho presente, a componente G representa a quantidade de verde e o eixo B apresenta a quantidade de azul. Qualquer cor no espaço RGB é representada como uma porção que varia de 0 a 255 de vermelho, verde e azul. Esse espaço de cores é geralmente bastante utilizado, pois muitos dispositivos de captura de imagens e dispositivos de saída de imagens como monitores e televisores em geral utilizam-no como padrão. A Figura 2.3 mostra a representação do espaço RGB.

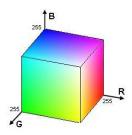


Figura 2.3: Espaço de cores RGB

2.2 Conceitos de Álgebra

Nessa seção serão apresentados conceitos básicos de álgebra linear que ajudam no entendimento de algumas das técnicas de reconhecimento de faces apresentadas nesse trabalho, como *Eigenfaces* e *Fisherfaces*.

Os conceitos de matrizes apresentados a seguir foram baseados no livro de Hoffman e Kunze [HK79].

2.2.1 Matriz

Uma matriz é uma tabela bidimensional de dimensão $m \times n$, onde m representa o número de linhas e n o número de colunas. As matrizes são utilizadas como instrumentos matemáticos na resolução de sistemas de equações, transformações lineares e diversas outras aplicações. Em 2.1 é apresentada uma matriz de 4 linhas e 4 colunas e seus elementos.

$$M = \begin{bmatrix} m_{11} & m_{12} & m_{13} & m_{14} \\ m_{21} & m_{22} & m_{23} & m_{24} \\ m_{31} & m_{32} & m_{33} & m_{34} \\ m_{41} & m_{42} & m_{43} & m_{44} \end{bmatrix}$$

$$(2.1)$$

Uma matriz é dita quadrada quando o número de linhas é igual ao número de colunas, conforme exemplo mostrado em 2.2. Uma matriz não quadrada possui o número de linhas diferente do número de colunas como mostra o exemplo 2.3.

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \tag{2.2}$$

$$B = \begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \end{bmatrix}$$
 (2.3)

Uma matriz pode ser também chamada de diagonal se os elementos da diagonal principal são diferentes de zero e todos os outros elementos da matriz são nulos, a matriz apresentada em 5.1 é uma matriz diagonal. Já a matriz identidade é aquela que todos os elementos da diagonal principal são iguais a 1 e o restante dos elementos são iguais a zero, conforme apresentado em 2.5.

$$C = \begin{bmatrix} c_{11} & 0 & 0 \\ 0 & c_{22} & 0 \\ 0 & 0 & c_{33} \end{bmatrix}$$
 (2.4)

$$I = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \tag{2.5}$$

Existem também os vetores linha e os vetores coluna. Vetores linha são matrizes que possuem apenas uma linha (2.6). Já os vetores coluna são matrizes que possuem uma coluna, como mostra a matriz 2.7.

$$X = \left[\begin{array}{ccc} x_{11} & x_{12} & x_{13} & x_{14} \end{array} \right] \tag{2.6}$$

$$X = \begin{bmatrix} x_{11} \\ x_{21} \\ x_{31} \\ x_{41} \end{bmatrix} \tag{2.7}$$

2.2.2 Determinante

O determinante é um valor associado a uma matriz quadrada que normalmente é utilizado na resolução de sistemas lineares. O exemplo 2.8 apresenta uma matriz quadrada de ordem 2 e a equação 2.9 mostra como calcular o determinante para uma matriz quadrada genérica de ordem 2. Para matrizes de ordem 3, a fórmula para se calcular o determinante é apresentada na expressão 2.13, que é o resultado da soma das equações 2.11 e 2.12. Para matrizes de ordem maior que 3 deve-se utilizar outros métodos, como o de LaPlace.

$$X = \begin{bmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \end{bmatrix} \tag{2.8}$$

$$det(X) = x_{11} * x_{22} - x_{12} * x_{21}$$
(2.9)

$$X = \begin{bmatrix} x_{11} & x_{12} & x_{13} \\ x_{21} & x_{22} & x_{23} \\ x_{31} & x_{32} & x_{33} \end{bmatrix}$$
 (2.10)

$$A = x_{11} * x_{22} * x_{33} + x_{12} * x_{23} * x_{31} + x_{13} * x_{21} * x_{32}$$
 (2.11)

$$B = x_{31} * x_{22} * x_{13} + x_{32} * x_{23} * x_{11} + x_{33} * x_{12} * x_{21}$$
 (2.12)

$$det(X) = A - B \tag{2.13}$$

2.2.3 Operações com Matrizes

Pode-se realizar operações com matrizes como transposta, soma, subtração, multiplicação por escalar ou multiplicação entre matrizes. A operação transposta realiza uma permuta das linhas e colunas da matriz original, isto é, o que é linha passa a ser coluna e vice-versa, como mostra a matriz de exemplo de 2.20 e sua transposta 2.15.

$$A = \begin{bmatrix} 1 & 5 & 11 \\ 3 & 9 & 4 \end{bmatrix} \tag{2.14}$$

$$A^{T} = \begin{bmatrix} 1 & 3 \\ 5 & 9 \\ 11 & 4 \end{bmatrix} \tag{2.15}$$

Para se fazer operações de soma ou subtração de matrizes é necessário que o número de linhas e o número de colunas sejam iguais nas matrizes que serão somadas ou subtraídas. Nas operações de soma e subtração, as operações são realizadas entre os elementos da mesma posição nas matrizes originais e o resultado dessas operações serão os elementos da matriz resultante, que possui a mesma dimensão dos operandos. Os exemplos 2.16 e 2.17 mostram a realização de cada uma dessas operações.

$$\begin{bmatrix} 1 & 7 & 4 \\ 3 & 2 & 9 \end{bmatrix} + \begin{bmatrix} 3 & 5 & 12 \\ 2 & 13 & 7 \end{bmatrix} = \begin{bmatrix} 1+3 & 7+5 & 4+12 \\ 3+2 & 2+13 & 9+7 \end{bmatrix}$$
 (2.16)

$$\begin{bmatrix} 1 & 7 & 4 \\ 3 & 2 & 9 \end{bmatrix} - \begin{bmatrix} 3 & 5 & 12 \\ 2 & 13 & 7 \end{bmatrix} = \begin{bmatrix} 1 - 3 & 7 - 5 & 4 - 12 \\ 3 - 2 & 2 - 13 & 9 - 7 \end{bmatrix}$$
(2.17)

A operação de multiplicação pode ser efetuada entre escalares e matrizes ou entre matrizes e matrizes. A multiplicação por escalar é realizada multiplicando-se cada um dos elementos da matriz por um escalar qualquer, o resultado será uma matriz com a mesma dimensão da matriz original com seus elementos multiplicados pelo escalar (ver exemplo 2.18). Já a multiplicação entre matrizes só é possível se, e somente se, dadas duas matrizes A de dimensão $M \times N$ e B de dimensão $X \times Y$, N = X, o resultado será uma matriz de dimensão $M \times Y$. A multiplicação entre matrizes está exemplificada em 2.19.

$$(3) * \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix} = \begin{bmatrix} 1 * 3 & 2 * 3 & 3 * 3 \\ 4 * 3 & 5 * 3 & 6 * 3 \end{bmatrix}$$
 (2.18)

$$\begin{bmatrix} 1 & 7 & 4 \\ 3 & 2 & 9 \end{bmatrix} * \begin{bmatrix} 1 & 3 \\ 5 & 9 \\ 11 & 4 \end{bmatrix} = \begin{bmatrix} 1*1+7*5+4*11 & 1*3+7*9+4*4 \\ 3*1+2*5+9*11 & 3*3+2*9+9*4 \end{bmatrix}$$
(2.19)

2.2.4 Matriz Inversa

A inversa de uma matriz é determinada pela propriedade $A*A^{-1}=I$, onde A é uma matriz quadrada, I é a matriz identidade e A^{-1} é a matriz inversa. Algumas matrizes não possuem inversa, essas matrizes são chamadas de não inversíveis ou singulares. Existem diversas maneiras de se calcular a matriz inversa, um dos métodos mais comuns é realizar diversas operações de pivotamento na matriz original para que ela se torna a matriz identidade. Seja a Matriz A definida por 2.20, e a matriz inversa A^{-1} definida por 2.21, sabemos que o resultado do produto da matriz A pela sua inversa A^{-1} será a matriz identidade I, como mostra a expressão 2.22. Ao se realizar as devidas multiplicações obteremos 3 sistemas de 3 incógnitas cada, mostrados em 2.23, 2.24 e 2.25, e o resultado será a matriz invertida 2.26.

$$A = \begin{bmatrix} 2 & 1 & 1 \\ 1 & 1 & 1 \\ 2 & 3 & 2 \end{bmatrix} \tag{2.20}$$

$$A^{-1} = \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & i \end{bmatrix}$$
 (2.21)

$$\begin{bmatrix} 2 & 1 & 1 \\ 1 & 1 & 1 \\ 2 & 3 & 2 \end{bmatrix} \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & i \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$
 (2.22)

$$\begin{cases}
2a+d+g=1 \\
a+d+g=0 \\
2a+3d+2g=0
\end{cases}$$
(2.23)

$$\begin{cases}
2b + e + f = 0 \\
b + e + h = 1 \\
2b + 3e + 2f = 0
\end{cases}$$
(2.24)

$$\begin{cases}
2c + f + i = 0 \\
c + f + i = 0 \\
2c + 3f + 2i = 1
\end{cases}$$
(2.25)

$$A^{-1} = \begin{bmatrix} 1 & 1 & 0 \\ 0 & -2 & 1 \\ -1 & 4 & -1 \end{bmatrix}$$
 (2.26)

2.2.5 Auto-vetores e Auto-valores

Um vetor coluna não nulo X de uma matriz quadrada A, é considerado um autovetor se existir um escalar λ , chamado de auto-valor, tal que, $AX = \lambda X \leftrightarrow AX = \lambda IX \leftrightarrow (A - \lambda I)X = 0$. A partir da solução da equação característica demonstrada em 2.27 de ordem n, pode-se encontrar os n autovetores de A, que podem ser reais, complexos ou nulos.

$$det(A - \lambda I) = 0 \leftrightarrow det \begin{pmatrix} a_{11} - \lambda & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} - \lambda & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} - \lambda \end{pmatrix}$$
 (2.27)

2.3 Aprendizagem Automática

2.3.1 Aprendizagem supervisionada e não-supervisionada

Existem duas grandes divisões nos métodos de aprendizagem automática, esses podem ser supervisionados ou não-supervisionados. De acordo com o método escolhido, o modo de classificação e treinamento diferenciam-se entre si. A seguir serão melhores descritos cada um dos métodos. Os conceitos sobre os métodos de aprendizado automático comentados a seguir foram baseados com informações apresentadas por Mitchell no livro [Mit97].

Métodos supervisionados

Para utilização de métodos de aprendizagem supervisionados é necessário um conhecimento prévio do problema, isto é, ter um modelo detalhado das classes do problema e de exemplos de entrada relacionados com a saída esperada. Os métodos supervisionados utilizam como base para o treinamento, também chamado de aprendizado, exemplos de entradas marcadas por algum especialista relacionadas com uma classe de saída esperada. Esses métodos são bastante comuns e existem diversas técnicas de aprendizagem automática clássicas como as Redes Neurais Artificiais.

Métodos não-supervisionados

Os métodos de aprendizagem não-supervisionados são treinados a partir de dados não classificados previamente, são os próprios métodos que tentam determinar a quais classes os dados pertencem. Portanto, a estrutura organizacional do problema não é fornecida a priori e é de responsabilidade

do método em criá-la. Os algortimos seqüenciais e de agrupamento de dados estão entre as duas classes de algoritmos, normalmente, utilizadas na implementação de técnicas desse método.

2.3.2 Métodos de validação

Os métodos de validação são utilizados para determinar as taxas de erros e acertos a partir de determinados conjuntos de treinamento e classificação. Existem diversos métodos de validação, entre os mais comuns estão:

- Validação pelo conjunto de treinamento: nesse método de validação todo o conjunto de amostras são utilizados para fazer o treinamento e a classificação da técnica de aprendizagem automática.
- Validação através da divisão dos conjuntos de treinamento e classificação: nesse método de validação uma parte das amostras é utilizada apenas para realizar o treinamento, as amostras restantes são utilizadas para formar o conjunto de classificação.
- Validação cruzada: no método de validação cruzada são feitas várias configurações das amostras para serem utilizadas no conjunto de treinamento e também no conjunto de classificação. As configurações diferentes dos conjuntos de treinamento e de classificação são chamadas de dobras. Isto é, as amostras são separadas em determinadas instâncias para atuarem como dados para treinamento e em outras instâncias como dados para serem classificados.

Capítulo 3

Reconhecimento de Faces

3.1 Eigenfaces

A utilização de *Eigenfaces* para reconhecimento de faces foi apresentada por Turk e Pentland [TP91b] como uma alternativa na forma de abordagem do problema de reconhecimento. A proposta da técnica é utilizar atributos diferentes dos utilizados nas abordagens anteriores que eram geralmente baseadas nos olhos, nariz, boca e cabelo e passar a usar informações mais discriminantes da face. Para isso a proposta dos autores foi de usar a análise de componentes principais para fazer a extração dos atributos da imagem da face. Essa técnica é não supervisionada, isto é, não se tem o conhecimento das classes de antemão.

O princípio básico da técnica em questão é encontrar as componentes principais da distribuição de faces, ou os auto-vetores da matriz de co-variância dos conjuntos de faces, onde uma imagem é um ponto, ou um vetor, em um espaço dimensional elevado. Os auto-vetores podem ser descritos como um conjunto de atributos que juntos descrevem as relações entre as faces e os eigenfaces são as relações de cada auto-vetor com cada uma das imagens. [TP91b].

Cada imagem pode ser representada exatamente como uma combinação linear de eigenfaces. E toda imagem pode ser aproximada utilizando o melhor conjunto de eigenfaces, que são os auto-vetores que apresentam os maiores auto-valores e uma maior variância no conjunto de faces. O melhor conjunto de eigenfaces representa um sub-espaço dimensional de tamanho M, chamado de "face space", de todas as imagens possíveis.

É necessário passar por uma etapa de treinamento para se calcular os auto-vetores das imagens do conjunto de treinamento, os passos descritos por Turk e Pentland em [TP91a] são:

- 1. Separar imagens para o conjunto de treinamento e calcular os eigenfaces que definem o face space.
- Sempre que for encontrada uma nova imagem, calcular os M eigenfaces através da projeção da imagem de entrada para cada eigenface já calculado.
- 3. Determinar se a imagem é realmente de face e que ela pode ser usada no face space.
- 4. Se a imagem é de face, fazer o reconhecimento e apresentar o resultado se foi possível ou não reconhecer a face.
- 5. (Opcional) Se uma imagem não for reconhecida algumas vezes, podese inserir essa imagem à base de treinamento através dos cálculos das características da imagem.

Seja uma imagem f(x,y) uma matriz de dimensões NxN, onde cada um dos elementos (dx, dy) são pixels de intensidade de cor de 8bits. A imagem f terá um do espaço dimensional total igual a N^2 , logo, o tamanho do espaço dimensional de um conjunto de imagens será alto.

Em imagens que contêm faces pode ocorrer uma similaridade entre os pixels, então o espaço dimensional de um conjunto de imagens pode não ser aleatório, e pode assim ser representado por um subespaço dimensional menor. A motivação principal da análise de componentes principais é encontrar vetores que representam a distribuição de faces em todo espaço de imagens. Esses vetores formam o sub-espaço que é chamado de face space. Cada vetor possui tamanho igual a N^2 e descreve uma imagem de dimensão NxN e é uma combinação linear das imagens de face originais.

Seja o conjunto de imagens de face de treinamento formado por Γ_1 , $\Gamma_2, \Gamma_3, \cdots, \Gamma_M$, a média desse conjunto é definida pela expressão 3.1. Cada imagem do conjunto de treinamento diferencia-se da média pela relação $\Phi_i = \Gamma_i - \Psi$. Esse conjunto de vetores é então submetido a análise de componentes principais, para encontrar os melhor vetores que descrevem a distribuição das faces no espaço. O κ ésimo vetor, μ_{κ} , é escolhido de acordo com a expressão 3.2. Os vetores μ_{κ} e λ_{κ} são os auto-vetores e os auto-valores, respectivamente, da matriz de covariância 3.3, onde $A = \Phi_1, \Phi_2, \cdots, \Phi_M$.

$$\Psi = \frac{1}{M} \sum_{n=1}^{M} \Gamma_n \tag{3.1}$$

$$\lambda_{\kappa} = \frac{1}{M} \sum_{n=1}^{M} (\mu_{\kappa}^{T} \Phi_{n})^{2}$$
(3.2)

$$C = \frac{1}{M} \sum_{n=1}^{M} \Phi_n \Phi_n^T = AA^T$$
(3.3)

Agora é preciso calcular as combinações lineares entre as imagens de face Φ_i . Considerando v_i os auto-vetores de A^TA e multiplicando cada lado da equação por A tem-se a equação 3.4, onde o termo Av_i são os auto-vetores da matriz de co-variância $C = AA^T$.

Para encontrar os M auto-vetores é utilizada a equação 3.5, onde v_l são os auto-vetores de uma matriz $N \mathbf{x} N$ $L = A^T A$, onde $L_{MN} = \Phi_M^T \Phi_N$ e u_l são os eigenfaces.

$$AA^T A\nu_i = \mu_i A\nu_i \tag{3.4}$$

$$u_l = \sum_{\kappa=1}^{M} v_{l\kappa} \Phi_{\kappa} \tag{3.5}$$

3.2 Fisherfaces

A técnica chamada de fisherfaces é descrita por Belhumeur, Hespanha e Kriegman em [BHK97]. Segundo os autores. a análise discriminante de Fisher consegue encontrar sub-espaços que distribuem de maneira mais eficaz as classes do sistema. A abordagem por fisherfaces é supervisionada, isto é, tem-se conhecimento prévio das classes do sistema e isso pode melhorar a projeção dos dados pois as informações contidas nas classes são levadas em consideração nessa técnica, ao contrário da técnica Eigenfaces. O gráfico da Figura 3.1 compara as projeções feitas pela análise de componentes principais(PCA) e discriminante linear de Fisher(FLD), no gráfico são apresentadas duas classes, "+" e "o", o eixo X representa o atributo 1 e o eixo Y representa o atributo 2. O gráfico mostra a diferença nos resultados das projeções obtidas pelas técnicas baseadas em PCA e FLD, a projeção feita pela técnica PCA não consegue diferenciar as classes utilizando apenas um atributo, enquanto a projeção feita pela técnica FLD consegue diferenciar completamente utilizando um atributo apenas.

O método de Fisher seleciona a matriz ortogonal W, de tal forma que o espalhamento interclasses e o espalhamento intraclasses sejam maximizados. Seja o espalhamento interclasses, S_B , definido por 3.6, e o espalhamento intraclasses, S_W , definido por 3.7, onde μ_i é média da imagem da classe X_i , e N_i é o numero de amostras na classe X_i . A projeção ótima é determinada

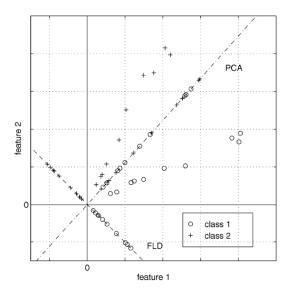


Figura 3.1: Comparação entre projeções realizadas por PCA e FLD (Hespanha e Kriegman em [BHK97])

pela matriz com colunas ortogonais que maximiza a relação entre os determinantes da matriz de espalhamento interclasses das amostras projetadas com o determinante da matriz de espalhamento intraclasses das amostras projetadas.

$$S_B = \sum_{i=1}^{c} N_i (\mu_i - \mu) (\mu_i - \mu)^T$$
 (3.6)

$$S_W = \sum_{i=1}^c \sum_{x_k \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T$$
(3.7)

Já o método descrito como Fisherfaces em [BHK97], consiste em fazer uma análise de componentes principais para reduzir o espaço dimensional de atributos para N-c, a seguir aplicar o discriminante linear de Fisher definido em 3.8 e reduzir a dimensão para c-1. Formalmente, a projeção ótima proposta pela técnica é definida pela equação 3.9, onde W_{pca} está definido em 3.10 e W_{fld} é definido como 3.11.

$$W_{opt} = \arg\max_{w} \frac{|W^T S_B W|}{|W^T S_W W|} \tag{3.8}$$

$$W_{opt} = W_{fld}^T W_{pca}^T (3.9)$$

$$W_{pca} = \arg\max_{w} |W^T S_T W| \tag{3.10}$$

$$W_{fld} = \arg\max_{w} \frac{|W^{T} W_{pca}^{T} S_{B} W_{pca} W|}{|W^{T} W_{pca}^{T} S_{W} W_{pca} W|}$$
(3.11)

Capítulo 4

Trabalhos Correlatos

Neste capítulo serão apresentadas técnicas de reconhecimentos de faces utilizadas em sistemas de segurança. Serão apresentadas também algumas aplicações das técnicas estudadas como *Eigenfaces* e *Fisherfaces*.

4.1 Reconhecimento de Faces em Sistemas

Brunelli e Poggio mostram uma comparação entre casamento de padrões e casamento de atributos geométricos [BP93]. O casamento de atributos geométricos consiste em extrair informações das características da face, como posições relativas e tamanho dos olhos, boca e nariz e comparar esses atributos com os de outras imagens. Já a técnica de casamento de padrões, utilizada pelos autores, consiste em fazer uma comparação das intensidades dos níveis de cinza das imagens de entrada com os padrões de face inteira. Esse trabalho assume que as imagens da face são frontais e a iluminação é uniforme.

Doi et al. apresenta um sistema para reconhecimento de faces invariante a alterações de iluminação, rotações e inclinações da face para controle de acesso a salas restritas [DSC98]. Esse sistema utiliza técnicas de casamento de atributos faciais (boca, nariz e olhos) para fazer o reconhecimento. Quando o sistema consegue casar os atributos faciais da imagem de entrada com os de alguma imagem presente no banco o acesso é liberado.

Um sistema de reconhecimento de face utilizado para segurança em tempo real é apresentado em [SGVA04]. Segundo os autores, esse sistema teve bons resultados com faces em condições adversas, como rotações, oclusões e variações de iluminação. Para o desenvolvimento desse sistema, fez-se o treinamento de uma rede neural para o problema da segmentação de pele e utilizou-se o método CPCA (Análise de Componentes Principais Composta)

que, segundo os autores, é responsável pela robustez na identificação de faces em situações complexas.

4.2 Análise de Componentes Principais e Discriminate de Fisher em Aplicações

Amorim e Pistori apresentam em [AP07] um sistema de classificação automático de couro bovino que utiliza análise discriminante de Fisher. Segundo os autores foi conseguida uma redução de 261 atributos extraídos para 16 atributos sem perder informações importantes para a classificação. As melhorias apresentadas pelos autores ficam por conta do tempo de processamento menor e maior precisão no reconhecimento.

Kurita et al. combina as técnicas de análise de componentes principais e classe de objetos lineares para fazer o reconhecimento de faces em um banco onde há apenas uma imagem por pessoa [KHH06]. O método de classes de objetos lineares é utilizado para fazer uma síntese virtual de imagens e assim conseguir gerar visualizações diferentes da imagem e melhorar o reconhecimento[VP97].

Cendrillon e Lovell, descrevem um sistema para reconhecimento facial em [CL00]. Segundo os autores, o sistema atingiu uma taxa de acertos de 94% mesmo em condições adversas, como variação de iluminação e variações nas posições da face. Um dos problemas apresentados foi o desempenho, o sistema roda na faixa de 2 quadros por segundo.

Capítulo 5

Desenvolvimento

A SIGUS¹ é uma biblioteca livre e gratuita que reúne diversas implementações na linguagem de programação Java de técnicas de visão computacional, aprendizagem automática e processamento digital de imagens. A plataforma SIGUS foi construída para auxiliar no desenvolvimento de aplicações com suporte a novas maneiras de interação homem-computador através de dispositivos de captura de imagens e para ajudar programadores a desenvolverem aplicações que possam ser utilizadas por pessoas com necessidades especiais.

Esse projeto foi desenvolvido com o auxílio da biblioteca SIGUS e as técnicas implementadas foram integradas a plataforma. Nesse projeto foram implementadas as técnicas de redução de atributos conhecidas como Eigenfaces e Fisherfaces utilizando a linguagem de programação Java. Para a implementação das técnicas escolhidas também foram utilizadas bibliotecas externas como Jama, ImageJ e Weka.

Jama é um framework Java para operações matemáticas e algébricas, como operações com matrizes, cálculo autovalores e autovetores. O ImageJ é uma aplicação livre desenvolvida em Java que reúne diversas implementações de algoritmos de processamento digital de imagens. O Weka é uma aplicação livre, também desenvolvida em Java, que oferece várias implementações de algoritmos de aprendizagem de máquina e fornece também facilidades para se realizar experimentos.

Para melhorar a integração com a plataforma SIGUS e para aumentar a escalabilidade do projeto desenvolvido, foi projetada uma estrutura baseada em orientação a objetos para facilitar a inclusão de novas técnicas baseadas em Análise Discriminante de Fisher. Existem diversos cálculos e passos comuns entre as técnicas baseadas em Análise Discriminante de Fisher e por

¹Para mais informações visite http://www.gpec.ucdb.br/sigus

isso usou-se o conceito de herança para facilitar a implementação das técnicas escolhidas para esse projeto e para outras existentes. A Figura 5.1 mostra o diagrama de classes simples da estrutura do projeto dentro da biblioteca SIGUS, outras técnicas baseadas em Análise Discriminante de Fisher estariam no mesmo nível que as classes FisherFace e EigenFace.

As classes implementadas foram: a classe Lda que é responsável pelos cálculos algébricos comuns entre muitas técnicas baseadas em Análise Discriminante de Fisher, a classe FunctionLda trabalha com os atributos utilizados nos arquivos de treinamento e classificação da ferramenta Weka, a classe UpdaterLda é quem cria os arquivos de entrada para a ferramenta Weka e as classes *EigenFace* e *FisherFace* implementam essas técnicas. Trechos de códigos das classes implementadas podem ser visualizadas nas Figuras 5.2, 5.3 e 5.4.

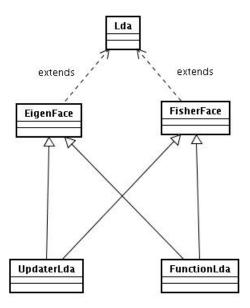


Figura 5.1: Diagrama de classes que representa o modelo implementado.

```
public Matrix calculate(String urlInstancesWekaIn, String urlInstancesWekaOut, boolean save, int r) {
   Instances instances = null;
    FileReader reader = null;
        reader = new FileReader(new File(urlInstancesWekaIn));
        instances = new Instances(reader);
    } catch (FileNotFoundException e) {
        e.printStackTrace();
    } catch (IOException e) {
        e.printStackTrace();
    instances.setClassIndex(instances.numAttributes()-1);
    List listaMatriz = function.createListClassArff(instances);
    //Calcula a matriz de redução por FLDA;
    Matrix matrizCLDA = calculateEigenFace(listaMatriz, instances.numAttributes()-1,r);
        //Cria uma lista contendo os novos valores reduzidos;
        List listaClasses = function.getListClass(instances);
        //Cria uma lista contendo os novos valores do ARFF setado;
        List listaValores = function.getListNewValues(listaMatriz, matrizCLDA);
        instances = updater.update(instances,listaValores,listaClasses,r,urlInstancesWekaOut);
    try {
        reader.close();
        instances.delete();
    } catch (IOException e) {
        e.printStackTrace();
    return matrizCLDA;
```

Figura 5.2: Trecho de código da função que faz a redução de atributos a partir de um arquivo .arff de entrada.

```
public Matrix calculateEigenFace(List listaMatriz, int m, int r) {
    Matrix Sw = covarianciaIntra(listaMatriz,m);
    EigenvalueDecomposition ev = Sw.eig();
    Matrix eigenVectors = ev.getV();
    Matrix eigenValues = ev.getD();
    Matrix matriz = maioresEigen(eigenVectors,eigenValues,r);
    return matriz;
}
```

Figura 5.3: Trecho de código que implementa os cálculos da técnica *Eigenfaces*.

```
* Função principal que retorna a matriz reduzida por Fisher;
* @param lista Lista contendo as informações para a redução;

* @param M Quantidade atual de atributos;

* @param R Quantidade informada para ser reduzido;
 * @return Retorna a matriz reduzida
public Matrix calculateFisherFace(List lista, int M, int R ) {
    Matrix Sw = covarianciaIntra(lista, M);
    EigenvalueDecomposition ev = Sw.eig();
    Matrix eigenVectors = ev.getV();
    Matrix eigenValues = ev.getD();
    Matrix pca = maioresEigen(eigenVectors,eigenValues,R);
    listaClasses = function.getListClass(instances);
    listaValores = function.getListNewValues(listaMatriz, pca);
    instances = updater.update(instances, listaValores, listaClasses, R, urlInstancesWekaOut);
    Matrix Sb = covarianciaInter(lista,M);
    Matrix pcaT = pca.transpose();
    Matrix termo = pcaT.times(Sw).times(pca); // pca'*Sw*pca
    Matrix termo2 = pcaT.times(Sb).times(pca); // pca'*Sb*pca
    Matrix Sf = termo.inverse().times(termo2); // Sf = inv(pcg'*Sw*pcg)*(pcg'*Sb*pcg);
    ev = Sf.eig();
    eigenVectors = ev.getV();
    eigenValues = ev.getD();
    Matrix matriz = maioresEigen(eigenVectors,eigenValues,R);
    return matriz;
```

Figura 5.4: Trecho de código que implementa os cálculos da técnica Fisher-faces.

Capítulo 6

Experimentos, Resultados e Análise

Para realização dos experimentos foi escolhido o banco de imagens disponibilizado pelo Dr. Libor Spacek¹ que contém 380 imagens de faces de mulheres e 2260 imagens de faces de homens. Os experimentos foram realizados portanto com o total de 2640 imagens divididas entre 132 pessoas. Esse banco de imagens foi escolhido por apresentar fundo fixo nas imagens de face, já que o objetivo desse projeto era verificar a eficiência de técnicas de redução de atributos no reconhecimento de faces e as imagens não passariam por nenhum processo de segmentação de imagens. As imagens do banco possuem resolução de 180x200 pixels e estão no formato JPEG e RGB. As imagens do banco possui apenas uma face de uma determinada pessoa e as expressões faciais e posições da face variam de uma imagem para outra. A Figura 6.1 demonstra algumas das imagens de faces masculinas e femininas presentes no banco de imagens utilizado.

Para a realização dos experimentos foi utilizada a ferramenta Weka, que possui implementações de várias técnicas de aprendizagem automática e um ambiente preparado para se realizar experimentos. O Weka interpreta arquivos no formato .arff, são nestes arquivos que estão definidas as classes e os valores dos atributos para os classificadores. Para os experimentos realizados nesse projeto, os atributos utilizados foram os valores dos pixels da imagem em RBG e as classes foram definidas como o nome das pessoas.

A seguir serão detalhadas as metodologias dos experimentos realizados e serão feitas as análises dos resultados obtidos.

¹Disponível em http://www.essex.ac.uk/mv/allfaces/index.html

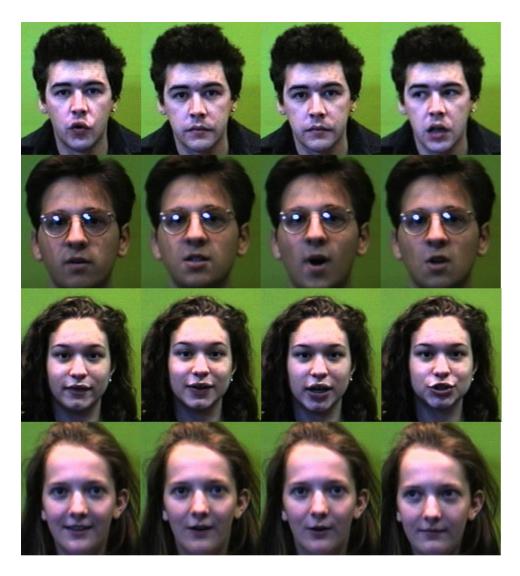


Figura 6.1: Exemplos de imagens de faces masculinas e femininas presentes no banco de imagens utilizado.

6.1 Experimento 1 - Verificar influência da resolução de imagens digitais de face na classificação automática

6.1.1 Descrição do experimento

A resolução das imagens que são disponibilizadas no banco de imagens é de 180x200, portanto são ao todo 36.000 atributos, um número muito grande de informação que poderia ser irrelevante para as técnicas de aprendizagem automática. Levando-se em consideração que em uma imagem que contém apenas uma face humana os pixels variam pouco, achou-se interessante averiguar se seria possível reduzir a resolução das imagens e manter a taxa de acerto dos classificadores automáticos. Essa verificação é importante pois espera-se que com menos atributos diminua a carga de cálculos computacionais realizados na aprendizagem e classificação automática.

Para a realização desse experimento, as imagens na resolução original foram submetidas a processos de redimensionalizações de até 3% do tamanho original. Para a redimensionalização foi utilizado um algoritmo que recebe uma imagem de entrada e redimensiona a resolução original para a resolução desejada, esse processo é feito transformando os valores originais da largura e do comprimento das imagens para valores definidos pelo usuário, e depois salva um cópia da imagem, no mesmo formato da imagem de entrada, em disco. O algoritmo de redimensionalização foi implementado utilizando a ferramenta ImageJ e a linguagem de programação Java. Posteriormente foram gerados arquivos de entrada para a ferramenta Weka com imagens de faces só de mulheres, imagens de faces só de homens e imagens de faces de homens e mulheres no mesmo conjunto. Foram ao total experimentadas 17 resoluções diferentes. Os conjuntos de imagens foram divididos da seguinte forma: para resoluções de 180x200 pixels a 96x105 pixels foram utilizadas 380 imagens de faces de mulheres, 380 de faces de homens e 380 imagens de faces dos dois gêneros misturadas, divididas entre 19 mulheres e 19 homens. Para as resoluções de 87x95 pixels a 30x32 pixels foram utilizadas 380 imagens de faces de mulheres, 1280 imagens de faces de homens e 760 imagens de faces de homens e mulheres juntas, divididas entre 19 mulheres e 64 homens.

Para esse experimento foram escolhidos os algoritmos de aprendizagem automática J48, SMO e IBK, todos disponíveis na ferramenta Weka e utilizou-se o método de validação cruzada com 2 dobras.

6.1.2 Resultados e análises

Os gráficos das Figuras 6.2, 6.3 e 6.4 e mostram os resultados obtidos para cada uma das resoluções testadas com cada um dos classificadores nos conjuntos de mulheres, homens e misto, respectivamente. Pode-se perceber que a porcentagem de acerto dos classificadores não diminui significativamente com a redução da resolução das imagens e essa redução de informação é bastante interessante pois pode contribuir com a diminuição da utilização de recursos computacionais. Os resultados obtidos apresentaram também que para algumas resoluções menores os resultados da classificação foram melhores, isso pode ser decorrente da redimensionalização ser feita na imagem inteira e ao se fazer essa transformação na imagem, pode-se excluir pixels que influenciavam negativamente nos métodos de aprendizagem automática. Pode-se perceber também que o algoritmo J48, que é baseado em árvores de decisão, foi o que apresentou a maior variação nos resultados obtidos na classificação, com isso conclui-se que ao se reduzir a resolução da imagem através da transformação dos valores da altura e do comprimento não são suficientes para determinar se haverá ganho, ou perda, nas taxas de classificação. Os dados obtidos com esse experimento podem ser visualizados nos Anexos A.1, A.2 e A.3.

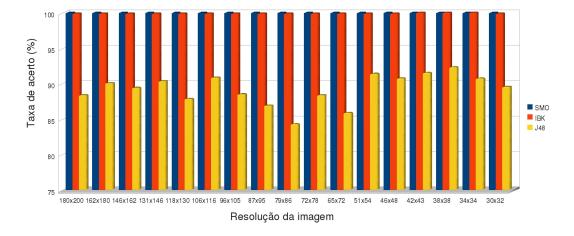


Figura 6.2: Resultados das classificações após reduções de resolução com imagens de faces de mulheres

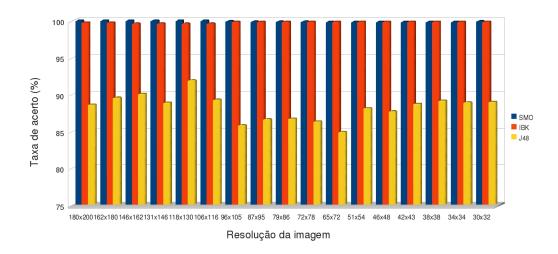


Figura 6.3: Resultados das classificações após reduções de resolução com imagens de faces de homens

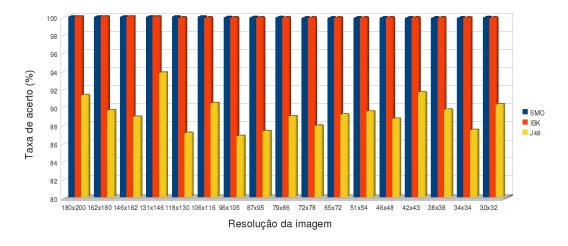


Figura 6.4: Resultados das classificações após reduções de resolução com imagens de faces de ambos os sexos

6.2 Experimento 2 - Confirmação dos resultados obtidos com a resolução escolhida

6.2.1 Descrição do experimento

Após a realização do Experimento 1, conseguiu-se perceber que a resolução da imagem não influencia muito na classificação das imagens, por isso a menor resolução testada foi escolhida por ser mais fácil de ser trabalhada computacionalmente. Entretanto, para garantir a representatividade do conjunto de imagens de tamanho menor, foi realizado um novo experimento para verificar se os algoritmos apresentariam o mesmo desempenho para o banco de imagens completo e utilizando-se um maior número de classificadores.

Para realização desse experimento foram utilizados 3 conjuntos de imagens. Um conjunto contendo apenas imagens de faces femininas, outro conjunto contendo apenas imagens masculinas e outro conjunto contendo imagens de faces femininas e masculinas. Para o conjunto de imagens de mulheres foram utilizadas 380 imagens, divididas entre 19 mulheres. Para o conjunto de imagens masculinas foram utilizadas 2260 imagens, divididas em 113 homens. E para o conjunto misto foram utilizadas 760 imagens, divididas entre 19 homens e 19 mulheres.

A partir das imagens escolhidas foram gerados 3 arquivos de entrada para a ferramenta Weka, um arquivo para cada conjunto de imagens, onde os valores dos pixels foram utilizados como atributos. Os arquivos gerados foram experimentados utilizando 10 técnicas de aprendizagem automática. Foram escolhidos os métodos: J48, SMO, IBK, FLR, Bayes Net, Naive Bayes, Multiclass Classifier, LogitBoost, Classification via Regreesion e Random Forest. Para cada uma das técnicas escolhidas foi utilizada validação cruzada com 10 dobras.

6.2.2 Resultados e análises

As Tabelas A.4, A.5, A.6, mostram os resultados obtidos após o término do experimento. Podemos perceber que a taxa de acerto dos classificadores permaneceram acima dos 99% para a maioria dos métodos escolhidos. Os resultados obtidos confirmaram a hipótese de que a representatividade das imagens fica praticamente estável após passarem por um processo de redimensionalização de cerca de 97%.

6.3 Experimento 3 - Encontrar taxa de redução a ser utilizada na técnica *Eigenfaces* para a aplicação da técnica *Fisherfaces*

6.3.1 Descrição do experimento

A técnica Fisherface utiliza uma primeira projeção de dados realizada pela técnica Eigenface, o trabalho de Hespanha e Kriegman [BHK97] define que a primeira projeção feita pela técnica Eigenfaces deve ser igual a diferença N-c, onde N é o número de atributos e c o número de classes do problema. No entanto, esse valor é definido para evitar ter o problema com matrizes singulares e não há garantia que esse seja o valor ótimo, ou próximo, para a projeção inicial.

Esse experimento foi realizado para tentar achar uma boa redução com a técnica Eigenface antes de se fazer a redução dos atributos com Fisherface. Para se realizar esse experimento utilizou um conjunto misto de imagens, contendo faces de homens e mulheres em quantidades iguais, 760 imagens divididas entre 19 pessoas de cada sexo, 38 classes ao total, e resolução de 30x32 que dá um total de 960 atributos. Para esse experimento não foi utilizada a taxa de redução de N-c proposta por Hespanha e Kriegman, no entanto a taxa de redução pela técnica Eigenfaces foi variada de 5 a 50% do número total de atributos. Com a taxa de redução inicial variável, fixou-se a taxa de redução da técnica Fisherfaces em c-1 de acordo com a propostas dos autores citados. E, para verificar se os parâmetros propostos no trabalho de Hespanha e Kriegman conseguem boa taxa de classificação, foi configurado um teste contendo 19 classes femininas, 38 mistas e 113 masculinas, cada uma das classes compostas com 20 imagens, com uma redução de N-c com a técnica Eigenfaces antes de se aplicar a redução de c-1 com a técnica Fisherfaces.

O objetivo desse experimento é analisar os resultados obtidos pelos classificadores utilizando-se as seguintes abordagens: fixar a taxa de redução da técnica Eigenfaces em N-c de acordo com a proposta de Hespanha e Kriegman e variar a taxa de redução com a técnica Eigenfaces de 5 a 50% antes de se reduzir para c-1 com a técnica Fisherfaces. Com o fim do experimento, pretendia-se obter a melhor taxa de redução que deve ser executada com a técnica Eigenfaces antes de aplicar a redução feita pela técnica Fisherfaces.

Para esse experimento foram utilizados os classificadores Bayes Net, Naive Bayes e IBK e foi utiliado o método de validação cruzada com 10 dobras.

6.3.2 Resultados e análises

A Tabela Anexo A.7 apresenta os resultados obtidos utilizando os parâmetros propostos por Hespanha e Kriegman em [BHK97]. Os resultados obtidos que o desempenho de 100% para todos os classificadores com os conjuntos misto e feminino. Com o conjunto masculino os resultados obtidos também foram bons, em torno de 95%.

A tabela Anexo A.8 mostra os resultados obtidos com a variação de 5 a 50% do tamanho original de atributos antes de se aplicar a técnica *Eigenfaces* no conjunto misto. Os resultados obtidos demonstram que até uma redução inicial de 35% as taxas de classificação não se alteram.

Portanto, pode-se concluir que apesar dos parâmetros propostos por Hespanha e Kriegman terem obtidos resultados satisfatórios, é possível no entanto reduzir um número maior de atributos com a técnica *Eigenfaces* antes da aplicação da técnica *Fisherfaces*. Essa redução inicial maior pode ajudar a técnica a ser aplicada posteriormente, já que o conjunto de dados de entrada se torna menor.

6.4 Experimento 4 - Comparação entre as taxas de classificação das técnicas escolhidas

6.4.1 Descrição do experimento

Após escolher-se a resolução de imagem a ser utilizada, 30x32 que ao todo possui 960 pixels, nos experimentos, e determinar uma taxa de redução inicial para a técnica Eigenfaces antes da execução da técnica Fisherfaces, foi-se realizado esse experimento para comparar as taxas de acertos das duas técnicas escolhidas após a realização de reduções de atributos gradativas. Para a realização desse experimento foram separadas as imagens de faces em 3 conjuntos, dos quais um dos conjuntos era composto apenas por imagens de mulheres, outro conjunto era composto apenas por imagens de homens e o último era composto de imagens de homens e mulheres. Para o conjunto de imagens de faces femininas foram utilizadas 380 imagens, 20 imagens de 19 mulheres. No conjunto masculino utilizou-se 20 imagens de 113 homens diferentes, portanto ao total foram utilizadas 2260 imagens. Para o conjunto misto, foram utilizadas no total 780 imagens, sendo 20 imagens para cada 19 pessoas de cada sexo.

O objetivo desse experimento era verificar quais os desempenhos que as 3 técnicas de aprendizagem automática que apresentaram os melhores resultados no Experimento 2 obteriam após a redução gradual dos atributos da

imagem através dos métodos escolhidos. Neste experimento foram utilizados os classificadores IBK, Naive Bayes e Bayes Net com o método de validação cruzada com 10 dobras.

A seguir os experimentos serão detalhados para cada técnica de redução de atributos escolhidas nesse projeto.

Redução de atributos com a técnica Eigenfaces

Nos experimentos realizados para a técnica *Eigenfaces*, para cada um dos conjuntos de imagens separados, foram feitas reduções graduais de 5 em 5% do tamanho original de atributos. A técnica *Eigenfaces* gera um novo conjunto de atributos, através da projeção dos dados, e a partir desses novos atributos foram criados arquivos de entrada para a ferramenta Weka. Para a classificação, os arquivos gerados pelos novos atributos foram executados na ferramenta Weka com as configurações descritas anteriormente para obtenção dos resultados.

Resultados e Análises do Experimento com a técnica Eigenfaces

O término dos experimentos (veja as tabelas com resultados, nos Anexos A.9, A.10, A.11) apresentaram os resultados obtidos após a realização dos experimentos com a técnica Eigenfaces. Os resultados obtidos mostraram que a técnica conseguiu reduzir em 95% os atributos das imagens do conjunto feminino sem adicionar erros de classificação. Para o conjunto de imagens masculinas os resultados mostram foi possível realizar uma redução de 80% dos atributos originais e manter a taxa de classificação alta. Para o conjunto misto os resultados obtidos também comprovam que uma redução de 90% dos atributos originais não influenciam nos métodos de classificação. Em todos os conjunto experimentados, pode-se perceber também que a redução para somente 10 atributos pode ser utilizada dependendo do problema, pois as taxas de classificações corretas foram superiores a 93%.

Redução de atributos com a técnica Fisherfaces

O objetivo desse experimento era de avaliar o desempenho dos classificadores automáticos após variar-se a taxa de redução da técnica Fisherfaces. Para a realização desse experimento utilizou-se a taxa de redução inicialde 35%, obtida no Experimento 3, antes de reduzir os atributos com a técnica avaliada em todos os conjuntos de imagens. A variação foi de 5 em 5%, e a redução feita pela técnica Fisherfaces foi de 40 a 95% do número total de atributos. Com os resultados das reduções feitas, foram gerados arquivos de

entrada para a ferramenta Weka e foram utilizadas as configurações descritas anteriormente para obtenção dos resultados.

Resultados e Análises do Experimento com a técnica Fisherfaces

Após o término do experimento, pôde-se perceber que se obteve melhores nos conjuntos de imagens femininas e no conjunto misto. A redução pela técnica Fisherfaces nos conjunto feminino e misto apresentou taxa de classificação de 100% em todas as configurações testadas, inclusive para a redução para 10 atributos totais no conjunto feminino. Para o conjunto de imagens masculino, os resultados obtidos foram abaixo do esperado, e foram piores que os resultados obtidos na aplicação da técnica Eigenfaces. As tabelas com os resultado obtidos nos conjuntos feminino, misto e masculino podem ser visulalizadas nos Anexos A.12, A.13, A.14.

6.5 Experimento 5 - Encontrar taxa de redução inicial para a aplicação da técnica *Fisher-faces* no conjunto de faces masculinas

6.5.1 Descrição do experimento

Após a realização do experimento anterior, verificou-se que o desempenho da técnica *Fisherface*, para o conjunto de faces masculinas, foi abaixo do esperado pelos relatos em trabalhos correlatos. Por esse motivo, realizou-se um pequeno experimento para verificar se a redução inicial de 35% feita com a técnica *Eigenface* prejudicou o desempenho da técnica estudada.

Esse experimento foi realizado com 1280 imagens de faces masculinas na resolução de $30\mathrm{x}32$ divididas entre 64 indivíduos. O experimento foi realizado seguindo a seguinte metodologia: foram feitas reduções de 5 a 95% do tamanho original de atributos utilizando a técnica *Eigenface* para depois fazer uma redução para um total de 47 atributos, que equivale a 5% do tamanho original de atributos.

Neste experimento utilizou-se os classificadores IBK e Naive Bayes e validação cruzada com 10 dobras.

6.5.2 Resultados e análises

A Tabela A.15 apresenta os resultados da variação de redução gradativa com *Eigenfaces* para depois se reduzir a um total de 47 atributos com a técnica *Fisherfaces*. De acordo com as taxas de classificações corretas obtidas,

6.5. Experimento 5 - Encontrar taxa de redução inicial para a aplicação da técnica *Fisherfaces* no conjunto de faces masculinas UCDB

a técnica Fisherfaces teria um resultado melhor se as reduções feitas com Eigenfaces fossem de 45% ao invés dos 35% utilizados no Experimento 4. Portanto, o desempenho abaixo do esperado da técnica Fisherfaces pode ser justificado por não terem sido usados parâmetros de redução com Eigenfaces que fossem mais ideais ao problema.

Capítulo 7

Conclusões e Trabalhos Futuros

Com o término do projeto, pode-se concluir que as duas técnicas estudadas, Eigenfaces e Fisherfaces, apresentaram bons desempenhos no reconhecimento facial. Conseguiu-se reduzir mais de 90% a quantidade de atributos em praticamente todos os experimentos nos conjuntos de imagens da faces de mulheres, homens e nos conjuntos mistos. A redução de atributos atingida é bastante expressiva, pois pode-se diminuir o poder computacional requerido para rodar as implementações das técnicas em sistemas reais já que o número de informações analisadas pelo classificador são menores.

Pôde-se perceber também que a resolução da imagem pode não influenciar de maneira significativa na classificação de imagens de face por métodos de aprendizagem automática. Muitos classificadores testados nesse projeto conseguiram manter as taxas de classificação das imagens acima de 90% somente com a redimensionalização da imagem, sem utilizar as técnicas de redução de atributos estudadas.

Os resultados alcançados mostraram também que a escolha da taxa de redução feita com a técnica Eigenfaces antes da utilização da técnica Fisher-faces pode ser determinante no desempenho de acordo com problema. Nesse projeto, a taxa escolhida conseguiu um desempenho muito bom, praticamente 100% em todos os experimentos para os conjuntos de imagens de faces femininas e para o conjunto misto. Para o conjunto masculino foi realizado um teste que confirma que a escolha inicial da taxa pode ter sido um dos principais fatores para o desempenho da técnica abaixo do esperado de acordo com os registros na literatura.

Por fim, foi possível confirmar os registros teóricos das diferenças entre as projeções dos dados feitas pelas duas técnicas. A técnica Eigenfaces conseguiu um desempenho que pode ser considerado bom, no entanto, quando escolheu-se uma taxa de redução inicial adequada conseguiu-se reduzir com a técnica Fisherfaces um número maior de atributos e manter as taxas de clas-

sificação elevadas. Logo, após os estudos realizados sobre as duas técnicas de redução de atributos e de se obter os resultados dos experimentos, pode-se concluir que a técnica *Fisherfaces* pode ser mais vantajosa para ser utilizada em sistemas de reconhecimento de faces, pois consegue realizar uma análise no conjunto de dados que leva em consideração as informações das classes e isso pode garantir resultados melhores em muitos problemas.

Como propostas de trabalhos futuros, pode-se citar:

- Utilizar segmentadores de pele para retirar da imagem qualquer elemento que não seja da face e realizar os experimentos descritos nesse projeto novamente para confirmação dos resultados obtidos.
- Realizar experimentos mais detalhados com o banco de imagens escolhido para identificar uma taxa de redução ideal com a técnica *Eigenfaces* antes da execução da técnica *Fisherfaces*.
- Realizar os experimentos com outros bancos de imagens.

Anexo A Tabelas de Resultados

Tabela A.1: Resultados Resolução da imagem	% acerto com SMO	<u> </u>	
180x200	100.00	99.87	88.33
162x180	100.00	99.87	90.03
146×162	100.00	99.87	89.37
131x146	100.00	99.87	90.29
118x130	100.00	99.87	87.80
106x116	100.00	99.87	90.82
96x105	100.00	99.87	88.46
87x95	100.00	99.87	86.88
79x86	100.00	99.87	84.26
72x78	100.00	99.87	88.33
65x72	100.00	99.87	85.83
51x54	100.00	99.87	91.34
46x48	100.00	99.87	90.69
42x43	100.00	100.00	91.47
38x38	100.00	100.00	92.26
34x34	100.00	100.00	90.68
30x32	100.00	99.87	89.51

Tabela A.2: Resultados do Experimento 1 para imagens de faces de homens.

Resolução da imagem	% acerto com SMO	% acerto com IBK	%acerto com J48
180x200	100.00	99.74	88.58
162x180	100.00	99.74	89.51
146×162	100.00	99.61	90.03
131x146	100.00	99.61	88.84
118x130	100.00	99.61	91.86
106 x 116	100.00	99.61	89.24
96x105	99.92	99.84	85.79
87x95	99.88	99.84	86.61
79x86	99.88	99.84	86.69
72x78	99.88	99.84	86.30
65x72	99.84	99.84	84.86
51x54	99.84	99.84	88.10
46x48	99.84	99.84	87.67
42x43	99.84	99.84	88.68
38x38	99.84	99.84	89.11
34x34	99.84	99.84	88.88
30x32	99.92	99.84	88.95

Tabela A.3: Resultados do Experimento 1 para imagens de faces de homens e mulheres.

Resolução da imagem	% acerto com SMO	% acerto com IBK	% acerto com J48
180x200	100.00	100.00	91.27
162x180	100.00	100.00	89.61
146x162	100.00	100.00	88.92
131x146	100.00	100.00	93.76
118x130	100.00	99.87	87.12
106x116	100.00	99.87	90.41
96x105	99.93	99.87	86.79
87x95	99.93	99.87	87.32
79x86	99.93	99.87	88.96
72x78	99.87	99.87	87.91
65x72	99.87	99.87	89.16
51x54	99.87	99.87	89.49
46x48	99.87	99.87	88.70
42x43	99.87	99.87	91.59
38x38	99.87	99.87	89.69
34x34	99.87	99.87	87.45
30x32	99.93	99.87	90.27

Tabela A.4: Resultados do Experimento 2 para imagens de faces de mulheres.

Classificador	% acerto
SMO	100.00
IBK	100.00
J48	95.22
FLR	100.00
Bayes Net	100.00
Naive Bayes	100.00
Multiclass Classifier	99.92
$\operatorname{LogitBoost}$	99.11
Classification via Regression	94.07
Random Forest	88.29

Tabela A.5: Resultados do Experimento 2 para imagens de faces de homens.

Classificador	% acerto
SMO	99.95
IBK	99.95
J48	91.89
FLR	99.92
Bayes Net	99.96
Naive Bayes	100.00
Multiclass Classifier	99.92
$\operatorname{LogitBoost}$	99.11
Classification via Regression	91.38
Random Forest	86.57

Tabela A.6: Resultados do Experimento 2 para imagens de faces de homens e mulheres.

Classificador	% acerto
SMO	100.00
IBK	100.00
J48	94.60
FLR	100.00
Bayes Net	100.00
Naive Bayes	100.00
Multiclass Classifier	99.87
$\operatorname{LogitBoost}$	99.65
Classification via Regression	91.38
Random Forest	86.57

Tabela A.7: Resultados do Experimento 3 para N-c e c-1.

Conjunto	% acerto Bayes Net	% acerto Naive Bayes	% acerto IBK
feminino	100.00	100.00	100.00
${ m masculino}$	95.98	98.11	98.98
misto	100.00	100.00	100.00

Tabela A.8: Resultados do Experimento 3 variando a redução com Eigenfaces e reduzindo para c-1 com Fisherfaces.

Redução	% acerto Bayes Net	% acerto Naive Bayes	%acerto IBK
5%	100.00	100.00	100.00
10%	100.00	100.00	100.00
15%	100.00	100.00	100.00
20%	100.00	100.00	100.00
25%	100.00	100.00	100.00
30%	100.00	100.00	100.00
35%	100.00	100.00	100.00
40%	99.93	100.00	100.00
45%	99.89	100.00	100.00
50%	99.79	99.88	100.00

Tabela A.9: Resultados do Experimento 4 com redução de atributos via Eigenfaces no conjunto de mulheres.

Número de atributos	Bayes Net % acerto	Naive Bayes % acerto	IBK $\%$ acerto
912	100.00	100.00	100.00
864	100.00	100.00	100.00
816	100.00	100.00	100.00
768	100.00	100.00	100.00
720	100.00	100.00	100.00
672	100.00	100.00	100.00
624	100.00	100.00	100.00
576	100.00	100.00	100.00
528	100.00	100.00	100.00
480	100.00	100.00	100.00
432	100.00	100.00	100.00
384	100.00	100.00	100.00
336	100.00	100.00	100.00
287	100.00	100.00	100.00
239	100.00	100.00	100.00
191	100.00	100.00	100.00
143	100.00	100.00	100.00
95	100.00	100.00	100.00
47	99.47	99.74	100.00
10	94.83	97.53	99.13

Tabela A.10: Resultados do Experimento 4 com redução de atributos via Eigenfaces no conjunto misto.

Número de atributos	Bayes Net % acerto	Naive Bayes % acerto	IBK $\%$ acerto
912	100.00	100.00	100.00
864	100.00	100.00	100.00
816	100.00	100.00	100.00
768	100.00	100.00	100.00
720	100.00	100.00	100.00
672	100.00	100.00	100.00
624	100.00	100.00	100.00
576	100.00	100.00	100.00
528	100.00	100.00	100.00
480	100.00	100.00	100.00
432	100.00	100.00	100.00
384	100.00	100.00	100.00
336	100.00	100.00	100.00
287	100.00	100.00	100.00
239	100.00	100.00	100.00
191	100.00	100.00	100.00
143	100.00	100.00	100.00
95	100.00	100.00	100.00
47	99.53	99.69	100.00
10	93.44	96.11	99.66

Tabela A.11: Resultados do Experimento 4 com redução de atributos via Eigenfaces no conjunto de homens.

Número de atributos	Bayes Net % acerto	Naive Bayes % acerto	IBK $\%$ acerto
912	100.00	100.00	100.00
864	100.00	100.00	100.00
816	100.00	100.00	100.00
768	100.00	100.00	100.00
720	100.00	100.00	100.00
672	100.00	100.00	100.00
624	100.00	100.00	100.00
576	100.00	100.00	100.00
528	100.00	100.00	100.00
480	100.00	100.00	100.00
432	100.00	100.00	100.00
384	100.00	100.00	100.00
336	100.00	100.00	100.00
287	100.00	99.98	100.00
239	100.00	99.99	100.00
191	100.00	99.89	99.96
143	99.97	99.75	99.96
95	99.93	99.53	99.91
47	99.67	99.43	99.86
10	93.69	96.61	99.25

Tabela A.12: Resultados do Experimento 4 com redução de atributos via Fisherfaces no conjunto feminino.

Número de atributos	Bayes Net % acerto	Naive Bayes % acerto	IBK $\%$ acerto
576	100.00	100.00	100.00
528	100.00	100.00	100.00
480	100.00	100.00	100.00
432	100.00	100.00	100.00
383	100.00	100.00	100.00
335	100.00	100.00	100.00
287	100.00	100.00	100.00
239	100.00	100.00	100.00
191	100.00	100.00	100.00
143	100.00	100.00	100.00
95	100.00	100.00	100.00
47	100.00	100.00	100.00
10	100.00	100.00	100.00

Tabela A.13: Resultados do Experimento 4 com redução de atributos via Fisherfaces no conjunto masculino.

Número de atributos	Bayes Net % acerto	Naive Bayes % acerto	IBK $\%$ acerto
576	99.56	99.12	99.66
528	99.57	99.19	99.66
480	99.58	99.23	99.75
432	99.62	99.32	99.66
383	99.60	99.36	99.67
335	99.59	99.40	99.69
287	99.58	99.42	99.77
239	99.57	99.47	99.77
191	99.57	99.48	99.84
143	99.48	99.52	99.81
95	99.02	99.49	99.77
47	96.43	98.49	99.18
10	61.38	75.51	79.77

Tabela A.14: Resultados do Experimento 4 com redução de atributos via Fisherfaces no conjunto misto.

Número de atributos	Bayes Net % acerto	Naive Bayes % acerto	IBK $\%$ acerto
576	100.00	100.00	100.00
528	100.00	100.00	100.00
480	100.00	100.00	100.00
432	100.00	100.00	100.00
383	100.00	100.00	100.00
335	100.00	100.00	100.00
287	100.00	100.00	100.00
239	100.00	100.00	100.00
191	100.00	100.00	100.00
143	100.00	100.00	100.00
95	100.00	100.00	100.00
47	100.00	100.00	100.00
10	99.50	100.00	99.99

Tabela A.15: Resultados do Experimento 5.

Redução em $\%$	Naive Bayes % acerto	IBK % acerto
5%	96.36	98.05
10%	97.67	99.20
15%	97.97	98.94
20%	98.90	99.31
25%	97.39	98.93
30%	98.09	98.97
35%	98.49	99.18
40%	97.17	98.15
45%	98.69	99.35
50%	96.11	97.38
55%	98.89	99.12
60%	96.33	96.05
65%	95.37	95.18
70%	96.56	97.33
75%	92.58	95.46
80%	92.56	92.17
85%	96.18	96.53
90%	95.81	94.21
95%	98.47	98.64

Referências Bibliográficas

- [AP07] Willian P. Amorim and Hemerson Pistori. Análise discriminante de fisher aplicadas à detecção de defeitos em couro bovino. *III* WVC Workshop de Visão Computacional, 2007.
- [BHK97] Peter N. Belhumeur, Joao Hespanha, and David J. Kriegman. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7):711–720, 1997.
- [BP93] R. Brunelli and T. Poggio. Face recognition: Features versus templates. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(10):1042–1052, 1993.
- [CL00] R. Cendrillon and B. Lovell. Real-time face recognition using Eigenfaces. In *Proc. of the SPIE International Conference on Visual Communications and Image Processing 2000*, volume 4067, pages 269–276, Perth, Australia, June 2000.
- [DSC98] M. Doi, K. Sato, and K. Chihara. A robust face identification against lighting fluctuation for lock control. In FG '98: Proceedings of the 3rd. International Conference on Face & Gesture Recognition, page 42, Washington, DC, USA, 1998. IEEE Computer Society.
- [FP03] David A. Forsyth and Jean Ponce. Computer Vision: A Modern Approach. Prentice Hall, August 2003.
- [GW01] Rafael C. Gonzalez and Richard E. Woods. Digital Image Processing. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 2001.
- [HK79] Kenneth Hoffman and Ray Kunze. Álgebra Linear. Livros Técnicos e Científicos Ed., 1979.

- [KHH06] Takio Kurita, Tatsuya Hosoi, and Akinori Hidaka. Principal component analysis of multi-view images for viewpoint-independent face recognition. In AVSS, page 55. IEEE Computer Society, 2006.
- [Mit97] Tom Mitchell. Machine Learning. McGraw Hill, 1997.
- [SGVA04] M. J. Seow, R. Gottumukkal, D. Valaparla, and K. V. Asari. A robust face recognition system for real time surveillance. In *ITCC '04: Proceedings of the International Conference on Information Technology: Coding and Computing (ITCC'04) Volume 2*, page 631, Washington, DC, USA, 2004. IEEE Computer Society.
- [TP91a] M.A. Turk and A.P. Pentland. Face recognition using eigenfaces.

 IEEE Computer Society Conference on Computer Vision and Pattern Recognition CVPR, 91:586-591, 1991.
- [TP91b] Matthew Turk and Alex Pentland. Eigenfaces for recognition. *J. Cognitive Neuroscience*, 3(1):71–86, 1991.
- [VP97] Thomas Vetter and Tomaso Poggio. Linear object classes and image synthesis from a single example image. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7):733–742, 1997.