

UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**RECONHECIMENTO BIOMÉTRICO DE ÍRIS  
USANDO FILTRO DE CORRELAÇÃO**

VOLNEI DA SILVA KLEHM

Manaus - Amazonas

Setembro de 2013

UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**RECONHECIMENTO BIOMÉTRICO DE ÍRIS  
USANDO FILTRO DE CORRELAÇÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

VOLNEI DA SILVA KLEHM  
ORIENTADOR: WALDIR SABINO DA SILVA JÚNIOR

Manaus - Amazonas  
Setembro de 2013

UNIVERSIDADE FEDERAL DO AMAZONAS

FOLHA DE APROVAÇÃO

Reconhecimento biométrico de íris usando filtro de correlação

VOLNEI DA SILVA KLEHM

Dissertação defendida e aprovada pela banca examinadora constituída por:

D. Sc. WALDIR SABINO DA SILVA JÚNIOR – Orientador  
Universidade Federal do Amazonas

D. Sc. CELSO BARBOSA CARVALHO  
Universidade Federal do Amazonas

D. Sc. FREDERICO DA SILVA PINAGÉ  
Fundação Centro de Análise, Pesquisa e Inovação Tecnológica

Manaus - Amazonas, Setembro de 2013

*Dedico esta dissertação a:*

*Hystheglidy Ramos Klehm*

*Isabel Ramos Klehm*

*Cauê Ramos Klehm*

# Agradecimentos

Dedico meus sinceros agradecimentos para:

- o professor doutor Waldir Sabino da Silva Júnior, pela orientação e incentivo;
- à coordenação do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, em especial ao professor doutor João Edgar, pela ajuda e suporte em diversos momentos;
- ao Centro de Ciência tecnologia e Inovação do Polo industrial de Manaus (CT-PIM), pelo apoio e disponibilização de tempo para realização deste trabalho;
- à minha esposa Hysther, pela revisão deste trabalho;
- à todos os meus professores e colegas do curso de Mestrado da Universidade Federal do Amazonas

# Resumo

Naturalmente, os padrões os quais desejamos reconhecer, ocorrem nas mais diversas formas. Por exemplo, supondo como padrão a íris humana, é natural que este padrão seja adquirido de algumas maneiras possíveis. Quando adquirida a íris pode estar, em relação ao padrão original, com rotação, translação, com efeitos de iluminação ou misturadas a ruídos. Dessa forma, em alguns casos, é necessário que o método de reconhecimento tenha versatilidade suficiente para identificar tais formas não esperadas da ocorrência do padrão os quais desejamos reconhecer. Em nosso caso particular, por exemplo, precisamos de filtros de correlação com flexibilidade mais ampla que os filtros SDF e MACE. Uma forma consolidada de expressar a variação de um conjunto de dados pode ser obtida utilizando-se o método por Análise de Componentes Principais (PCA) [1, 2]. A PCA representa de forma ótima um conjunto de dados e esse fato a torna interessante para combinação com o projeto de filtros e uma possível abordagem consiste em sua modificação para que as próprias componentes principais sejam usadas como padrões alvo. Nesta dissertação, é proposta a modificação do projeto de filtros de correlação SDF e MACE de modo a se utilizar a Análise de Componentes Principais para representar o conjunto das ocorrências do padrão de interesse. Um dos benefícios desta abordagem, reside no fato da PCA incorporar as variações presentes no conjunto de dados proporcionando, como resultado, filtros mais flexíveis. Assim, filtros projetados desta forma teriam sucesso na detecção de padrões com pequenas distorções, translações e rotações. Para validar o método proposto, projetamos um sistema de reconhecimento que utiliza como padrão a íris humana e, para tal, uma base de dados consolidada é utilizada.

# Abstract

Naturally, patterns that we wish to recognize occurs in several manners. As example, considering the ordinary human iris, it is often to this pattern to manifest different aspects. When acquired one iris can present, in relation to the original pattern, rotation, translation, lighting distortions or mixed noise. Thus, in some cases, it is necessary to the recognition method to have versatility enough to identify such unexpected forms of pattern occurrences that we wish to recognize. In our particular case, filters for correlation with broader flexibility than the standard SDF and MACE filters, for example, are necessary. A consolidated way to express the variation of a data set can be obtained using the method of Principal Component Analysis (PCA) [1, 2]. The PCA optimally represents a dataset and this fact makes it interesting for combination among ordinary correlation filter design and one possible approach consists of the modification of the design of correlation filters to use principal components as their own detection target. In this dissertation, it is proposed to modify the design of correlation filters SDF and MACE to use Principal Component Analysis to represent the set of occurrences of the pattern of interest. One benefit of this approach resides in the fact that PCA incorporate the changes in the set data providing as a result, more flexible filters. Thus, filters designed in this way would succeed in detecting patterns with small distortions translations and rotations. To validate the proposed method, a recognition system that uses the default human iris was designed and, for this purpose, one consolidate database is used.

# Sumário

<b>1</b>	<b>Fundamentos Teóricos</b>	<b>5</b>
1.1	Reconhecimento de Padrões . . . . .	5
1.1.1	Aquisição/Sensoriamento . . . . .	6
1.1.2	Pré-processamento . . . . .	8
1.1.3	Extração de Características . . . . .	8
1.1.4	Classificação . . . . .	8
1.1.5	Pós-processamento . . . . .	9
1.1.6	Treinamento . . . . .	10
1.2	Transformada Rápida de <i>Fourier</i> (FFT, <i>Fast Fourier Transform</i> ) . . .	11
1.3	Análise de Componentes Principais . . . . .	13
1.4	O Algoritmo <i>k-means</i> . . . . .	14
<b>2</b>	<b>Reconhecimento de Padrões por Correlação</b>	<b>17</b>
2.1	Introdução . . . . .	17
2.2	Função Discriminante Sintética . . . . .	19
2.3	Filtro de Correlação MACE . . . . .	20
<b>3</b>	<b>Filtros de Correlação SDF e MACE utilizando Análise de Componentes Principais</b>	<b>23</b>
3.1	Filtros de Correlação por Função Discriminativa Sintética e Análise de Componentes Principais (SDF-PCA) . . . . .	23
3.2	Filtros de Mínima Energia Média de Correlação com Análise de Componentes Principais (MACE-PCA) . . . . .	24
3.2.1	Métrica de detecção de picos de correlação . . . . .	25
3.2.2	Métrica de Classificação usada nos filtros MACE . . . . .	27
<b>4</b>	<b>Sistema de Reconhecimento de Íris utilizando Filtros de Correlação com Análise de Componentes Principais</b>	<b>29</b>
4.1	Coleta de Dados . . . . .	30
4.2	Pré-processamento . . . . .	32



4.3	Extração de Características . . . . .	33
4.4	Projeto do Classificador . . . . .	34
4.5	Avaliação de Desempenho . . . . .	37
<b>5</b>	<b>Resultados do Sistema de Reconhecimento de Íris</b>	<b>39</b>
5.1	Introdução . . . . .	39
5.2	Resultados Obtidos com Filtro SDF . . . . .	40
5.2.1	Desempenho em Função do Número de Componentes Principais	41
5.2.2	Desempenho em Função da Largura da Região Seleccionada . . . .	42
5.2.3	Desempenho em Função da Altura da Região Seleccionada . . . .	44
5.2.4	Desempenho em Função da Relação Sinal/Ruído . . . . .	46
5.2.5	Desempenho em Função da Relação Raio de Segmentação . . . .	47
5.2.6	Desempenho em Função do Número de Imagens de Treino . . . .	48
5.3	Resultados obtidos com Filtro MACE e Filtros MACE-PCA . . . . .	53
5.3.1	Comportamento dos Picos de Energia e Determinação de um Modelo para Validar Picos de Energia obtidos no Processo de Classificação . . . . .	53
5.3.2	Comportamento dos Picos de Energia e Determinação de um Modelo para Validar Picos de Energia obtidos no Processo de Classificação MACE-PCA . . . . .	53
5.3.3	Coefficiente de Sobreposição entre o Coeficiente de Correlação entre a Saída e o Modelo de Pico de Energia . . . . .	54
5.3.4	Resultado para os Teste de Verificação . . . . .	58
5.3.5	Resultado de Teste de Verificação em Função da Quantidade de Imagens de Treino . . . . .	59
5.3.6	Resultado de Teste de Variação da Largura . . . . .	60
5.3.7	Resultado de Teste de Variação de Fator de Escala . . . . .	63
5.3.8	Limiar de Classificação para Relação entre Pico e Desvio Padrão	66
5.3.9	Desempenho em Função da Largura medindo-se a Relação entre Pico e Desvio Padrão . . . . .	71
5.3.10	Desempenho em Função do Fator de Escala medindo-se a Relação entre Pico e Desvio Padrão . . . . .	76
	<b>Referências Bibliográficas</b>	<b>83</b>

# Lista de Figuras

1.1	Conceito de região de classificação e fronteira de decisão . . . . .	6
1.2	Sistema básico de reconhecimento de padrões. . . . .	7
1.3	Processo de quantização. . . . .	7
1.4	Análise de característica para ser usada em um classificador. . . . .	9
1.5	Modelo simplificado do processo de treinamento supervisionado. . . . .	10
1.6	Exemplo de agrupamento. . . . .	11
1.7	Modelo simplificado do processo de treinamento por reforço. . . . .	11
1.8	Algoritmo RADIX-2 para uma transformada de 8 pontos. . . . .	13
1.9	Algoritmo <i>k-means</i> . . . . .	15
1.10	Exemplo do algoritmo <i>k-means</i> . . . . .	16
2.1	Esquema de correlação de imagens. . . . .	18
2.2	Modelo de Classificador usando filtros de correlação . . . . .	19
2.3	Exemplo de saída obtida com um filtro MACE. . . . .	22
3.1	Exemplo de saídas obtidas com filtros MACE, à esquerda filtro tradicional, à direita resposta a um filtro MACE projetado para a primeira componente principal dos padrões de treino. Observar uma redução no valor de pico sem entretanto afetar significativamente a distinção deste em relação ao ruído lateral. . . . .	25
3.2	Definição geométrica do conceito de coeficiente de correlação. . . . .	26
3.3	Modelo de pico de energia obtido através de média. . . . .	27
3.4	Intersecção entre duas distribuições normais. quanto menor a intersecção entre o conjunto de valores para as classificações negativa e positiva, melhor é o parâmetro para classificação. . . . .	28
4.1	Etapas de desenvolvimento do sistema de classificação proposto. . . . .	29
4.2	Sistema de aquisição usado no subconjunto CASIA-Iris-Interval, imagem da <i>Chinese Academy of Sciences</i> . . . . .	31
4.3	Exemplo de imagens presentes no subconjunto CASIA-Iris-Interval. . . . .	31
4.4	Etapas de pré-processamento. . . . .	32

4.5	Resultado das etapas de pré-processamento. . . . .	32
4.6	Exemplo de resultado obtido através do uso da PCA (componente de maior variância em destaque). . . . .	33
4.7	Sistema de classificação usado neste trabalho. . . . .	35
4.8	Classificação por comparação. . . . .	36
4.9	Classificação por comparação. . . . .	37
5.1	Sistema de coordenadas adotado, imagem com resolução de $360 \times 100$ . . . .	40
5.2	Gráfico dos resultados para o experimento (teste) de desempenho em função do número de componentes principais. Em vermelho SDF-PCA, em azul SDF. . . . .	42
5.3	Gráficos dos resultados para o experimento (teste) de desempenho em função da largura da região selecionada. Em vermelho SDF-PCA, em azul SDF. . . . .	43
5.4	Gráficos dos resultados para o experimento (teste) de desempenho em função da altura da região selecionada. Em vermelho SDF-PCA, em azul SDF. . . . .	46
5.5	Gráficos dos resultados para o experimento (teste) de desempenho em função da relação sinal/ruído. Em vermelho SDF-PCA, em azul SDF. . . . .	47
5.6	Gráfico dos resultados para o experimento (teste) de desempenho em função do raio de segmentação. Em vermelho SDF-PCA, em azul SDF. . . . .	48
5.7	Gráfico dos resultados para o experimento (teste) de desempenho em função do número de imagens de treino. Em vermelho SDF-PCA, em azul SDF. . . . .	49
5.8	Média de picos de energia obtidos quando a imagem pertence ao conjunto de treinamento utilizadas no projeto do filtro de correlação. . . . .	54
5.9	Desvio padrão de cada ponto da Figura 5.8. . . . .	55
5.10	Média de picos de energia obtidos quando a imagem pertence ao conjunto de treinamento utilizadas no projeto do filtro de correlação. . . . .	55
5.11	Desvio padrão de cada ponto da Figura 5.8. . . . .	56
5.12	Distribuição estatística dos valores de correlação com o modelo para um filtro MACE-PCA. Em vermelho, zona de rejeição e em azul zona de aprovação. . . . .	57
5.13	Distribuição estatísticas dos valores de correlação com o modelo para um filtro MACE clássico (em vermelho zona de rejeição e em azul zona de aprovação). . . . .	57
5.14	Taxa de falsos positivos em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul. . . . .	60
5.15	Taxa de falsos negativos em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul. . . . .	60

5.16	Limiar de classificação em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul. . . . .	61
5.17	OVC em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul. . . . .	61
5.18	Taxa de falsos positivos em função da largura. MACE-PCA em vermelho, MACE em azul. . . . .	64
5.19	Taxa de falsos negativos em função da largura. MACE-PCA em vermelho, MACE em azul. . . . .	64
5.20	Limiar de classificação em função da largura. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	65
5.21	OVC em função da largura. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	65
5.22	Taxa de falsos positivos em função da escala. MACE-PCA em vermelho, MACE em azul. . . . .	68
5.23	Taxa de falsos negativos em função da escala. MACE-PCA em vermelho, MACE em azul. . . . .	68
5.24	Limiar de classificação em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	69
5.25	OVC em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	69
5.26	Análise ilustração da Tabela 5.22 para filtro do tipo MACE-PCA. Zona de rejeição em vermelho e zona de aprovação em azul. . . . .	70
5.27	Análise ilustração da Tabela 5.22 para filtro do tipo MACE. Zona de rejeição em vermelho e zona de aprovação em azul. . . . .	70
5.28	Taxa de falsos positivos em função da largura. MACE-PCA em vermelho, MACE em azul. . . . .	74
5.29	Taxa de falsos negativos em função da largura. MACE-PCA em vermelho, MACE em azul. . . . .	74
5.30	Limiar de classificação em função da largura. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	75
5.31	OVC em função da largura. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	75
5.32	Taxa de falsos positivos em função da escala. MACE-PCA em vermelho, MACE em azul. . . . .	78
5.33	Taxa de falsos negativos em função da escala. MACE-PCA em vermelho, MACE em azul. . . . .	78
5.34	Limiar de classificação em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	79

5.35 OVC em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'. . . . .	79
---	----

# Lista de Tabelas

4.1	Estatísticas do subconjunto CASIA-Iris-Interval. . . . .	30
5.1	Relação de parâmetros para o experimento de desempenho em função do número de componentes principais. . . . .	41
5.2	Resultados para o experimento (teste) de desempenho em função do número de componentes principais. . . . .	41
5.3	Relação de parâmetros para o experimento de variação da largura da região selecionada. . . . .	43
5.4	Resultados para o experimento (teste) de variação da largura da região selecionada. . . . .	44
5.5	Relação de parâmetros para o experimento de variação da largura da região selecionada. . . . .	45
5.6	Resultados para o experimento (teste) de desempenho em função da altura da área selecionada. . . . .	45
5.7	Relação de parâmetros para variação da relação sinal/ruído . . . . .	47
5.8	Resultados para o experimento (teste) de desempenho em função da relação sinal/ruído. . . . .	50
5.9	Parâmetros para o experimento variação do raio de segmentação. . . . .	51
5.10	Resultados para o experimento (teste) desempenho em função do raio de segmentação. . . . .	51
5.11	Parâmetros para o experimento variação do número de imagens de treino. . . . .	52
5.12	Resultados para o experimento (teste) desempenho em função do número de imagens de treino. . . . .	52
5.13	Parâmetros do experimento para detecção de picos de correlação. . . . .	54
5.14	Análise estatística do coeficiente de correlação da saída do filtro com o modelo de pico de energia. O limiar de classificação é o melhor ponto para separar classes negativas de positivas. . . . .	58
5.15	Comparativo entre taxas de falsos positivos e falsos negativos, $\mu$ representa a média e $\sigma$ é o desvio padrão. . . . .	58

5.16	Resultados obtidos variando-se o número de imagens de treino para o filtro MACE. . . . .	59
5.17	Resultados obtidos variando-se o número de imagens de treino para o filtro MACE-PCA. . . . .	59
5.18	Resultados obtidos variando-se a largura da região segmentada para o filtro MACE. . . . .	62
5.19	Resultados obtidos variando-se a largura da região segmentada para o filtro MACE-PCA. . . . .	63
5.20	Resultados obtidos variando-se a escala da região segmentada para o filtro MACE. . . . .	66
5.21	Resultados obtidos variando-se a escala da região segmentada para o filtro MACE-PCA. . . . .	67
5.22	Análise estatística da relação pico/desvio padrão da saída do filtro de correlação, o limiar de classificação é expresso nessa relação. . . . .	67
5.23	Resultados obtidos variando-se a largura da região segmentada para o filtro MACE. . . . .	72
5.24	Resultados obtidos variando-se a largura da região segmentada para o filtro MACE-PCA. . . . .	73
5.25	Resultados obtidos variando-se a escala da região segmentada para o filtro MACE. . . . .	76
5.26	Resultados obtidos variando-se a escala da região segmentada para o filtro MACE-PCA. . . . .	77

# Nomenclatura

- $P_r$  Relação entre valor de pico e desvio padrão no plano de correlação
- $R_{FN}$  Razão entre o número de falsos negativos e a quantidade total de classes legítimas testadas
- $R_{FP}$  Razão entre o número de falsos positivos e a quantidade total de classes impostoras testadas
- ACE Energia média de correlação
- CASIA Academia Chinesa de Ciências, Instituto de Automação
- CF Filtro de correlação
- CPR Reconhecimento de padrões por correlação
- DFT Transformada discreta de Fourier
- FFT Transformada rápida de Fourier
- MACE Mínima energia média de correlação
- MACE-PCA Filtro MACE modelado com as componentes principais das classes de treino
- MF Filtro casado
- MSF Filtro casado espacial
- OVC Coeficiente de sobreposição entre duas distribuições normais
- PCA Análise de componentes principais
- SDF Função discriminante sintética
- SDF-PCA Filtro SDF modelado com as componentes principais das classes de treino



# Introdução

Nas últimas décadas, diversos procedimentos para identificação de indivíduos foram desenvolvidos. Tradicionalmente, os sistemas projetados com estes procedimentos utilizam senhas ou chaves que representam limitações evidentes. Nesse contexto, nos últimos anos, surgiu um outro tipo de paradigma para identificação que utiliza traços físicos ou características comportamentais. Podemos usar faces [3], digitais [4], íris [5], assinaturas digitais, palma da mão [6], etc. Esse novo paradigma deu origem a um campo de pesquisa denominado por reconhecimento biométrico que pertence a área de reconhecimento de padrões.

Ao iniciarmos um estudo sobre reconhecimento de padrões, torna-se natural uma pergunta *O que é um padrão?*. Essa questão não é trivial e sua definição está no âmago das áreas relacionadas a inteligência artificial tão presente em uma série de campos de estudos. Pode-se definir padrão como sendo o oposto do caos, como uma entidade, por assim dizer, a qual se pode dar um nome [7]. Dessa forma, podemos mencionar que o reconhecimento de padrões é o processo através do qual a associação de um objeto a uma determinada classe é realizada e consiste no estudo de como máquinas podem observar o mundo, aprender a distinguir objetos de interesse e separá-los do restante da informação presente no meio para que possam tomar boas decisões tendo como base essa categorização [1]. Esse tipo de associação é frequentemente realizada por animais e é essencial a sobrevivência em seu meio natural. No contexto tecnológico, o reconhecimento automático de padrões é uma das bases da inteligência artificial e existem inúmeras aplicações, dentre elas: detecção automática de falhas [8], processamento de imagens de satélite [9, 10] e identificação biométrica de indivíduos [11, 12, 13].

Um Filtro de Correlação (CF) é um operador usado para detecção de ocorrências de um modelo de referência. O processo de detecção por meio de filtros de correlação enfatiza as regiões de ocorrência do modelo desejado através da medida de similaridade entre ele e o padrão candidato. Durante vários anos, o reconhecimento de padrões usando filtros de correlação foi feito através de correlacionadores coerentes ópticos para detecção de múltiplos objetos em aplicações militares. Devido ao advento de algoritmos

FFT [1] e da antiguidade dos dispositivos de entrada e saída dos correlacionadores ópticos pode-se dizer que os sistemas de reconhecimento de padrões por correlação atuais são em sua maioria digitais [14], com aplicações em diversas áreas, tais como: detecção automática de quais alvos [15, 14, 16], reconhecimento biométrico [17, 18], visão robótica e automação industrial [14].

Dentre as categorias de CF, os Filtros Casados [19] (MF) e sua variação espacial (MSF) constituem uma classe de filtros com desempenho ótimo, no sentido do erro médio quadrático, nos casos em que o modelo de referência está misturado com ruído branco [14]. Entretanto, normalmente encontramos modelos de referência misturados aos mais diversos tipos de ruídos ou distorções, tais como, rotação, translação, ruído impulsivo. Assim, podemos inferir que essa classe de filtros não é apropriada para tais casos. Para suprir tal necessidade de reconhecer modelos (padrões) misturados a outros tipos de ruídos ou distorções, foram propostos outros métodos [15] que combinam uma série de modelos que podem ser reconhecidos por um único filtro.

Um dos representantes desta nova classe de CF são os pertencentes à classe Função Discriminante Sintética (SDF) [20]. Nesta, o padrão de entrada é casado com um modelo composto pela combinação linear dos padrões de treino, esse filtro apresenta como principal limitação o baixo controle da energia no plano de correlação pelo fato de apenas a origem ser controlada, picos de energia em outras regiões do plano são comuns e podem ser maiores em relação ao obtido na origem, devido a esse fato é necessária a devida centralização ou compensação entre padrão de teste e filtro para evitar o deslocamento dos picos de correlação. Outro representante, que visa melhorar o controle sobre a energia no plano de correlação, são os pertencentes à classe MACE (*Minimum Average Correlation Energy*), a qual têm como objetivo a minimização da energia do plano de correlação e a criação de um pico energético bem definido e destacado. Esses filtros apresentam como vantagem a dispensa de centralização pois em caso de correlação positiva o pico de energia terá sempre destaque em relação ao restante do plano de correlação.

Conforme comentamos, os modelos (ou padrões) são encontrados, naturalmente, em diversas formas. Por exemplo, supondo como padrão a íris humana, é natural que este padrão seja adquirido das mais diversas formas, mesmo em ambientes controlados. A íris quando adquirida pode estar, em relação ao padrão original, com rotação, translação, com efeitos de iluminação ou misturadas a ruídos. Dessa forma, em alguns casos, é necessário que o método de reconhecimento tenha versatilidade suficiente para identificar tais formas não esperadas da ocorrência do padrão alvo. Em nosso caso particular, precisamos de filtros de correlação com flexibilidade mais ampla que os filtros SDF e MACE por exemplo. Uma forma consolidada de expressar a variação de um conjunto de dados pode ser obtida utilizando-se o método por Análise de Componen-

tes Principais (PCA) [1, 2]. A PCA objetiva a determinação de uma base ortogonal composta por autovetores da matriz de covariância dos dados ao qual é aplicada. Tais autovetores obtidos pela PCA são associados a uma direção de variação dos dados. Dessa forma, os autovetores podem ser ordenados no sentido das direção com maior variância. Além desses benefícios, a PCA oferece uma representação ótima, no sentido do menor erro quadrático, da variância dos dados. Essa característica inerente da PCA de representar de forma ótima um conjunto de dados é o que de fato a torna interessante para combinação com o projeto de filtros. Especificamente, podemos combinar a representação de um conjunto de dados por PCA com o projeto de filtros de correlação. Por exemplo, podemos modificar o projeto dos filtros de correlação SDF e MACE para utilizarem a própria PCA como padrões alvo.

Em síntese, nesta dissertação, é proposta a modificação dos projetos dos filtros de correlação SDF e MACE em versões alteradas MACE-PCA e SDF-PCA, nos quais, a Análise de Componentes Principais será utilizada para representar o conjunto das ocorrências do padrão de interesse. Um dos benefícios desta abordagem, reside no fato da PCA incorporar as variações presentes no conjunto de dados proporcionando, como resultado, filtros mais flexíveis. Assim, os filtros projetados desta forma teriam sucesso na detecção de padrões com pequenas distorções, translações e rotações. Para validar o método proposto, projetamos um sistema de reconhecimento que utiliza como padrão a íris humana. Para tal, uma base de dados consolidadas, adotada com frequência na comunidade científica, denominada CASIA-IrisV4 [21], é utilizada.

# Capítulo 1

## Fundamentos Teóricos

Neste capítulo, apresentamos os conceitos fundamentais para entendimento da proposta deste trabalho com o objetivo de demonstrar as definições e formulações matemáticas dos métodos envolvidos. A organização do capítulo é feita como segue: primeiramente, apresentamos e descrevemos o diagrama em blocos de um sistema de reconhecimento de padrões. A seguir, mostramos a formulação matemática da transformada de *Fourier* e da teoria por Análise de Componentes Principais. Por fim, apresentamos o algoritmo utilizado para classificação denominado *k-means*.

### 1.1 Reconhecimento de Padrões

A percepção do mundo exterior e sua compreensão em vários níveis é uma atividade rotineira humana, e tem sido essencial para nossa sobrevivência por milhões de anos [22]. Por exemplo, identificar faces consiste em uma tarefa comum e demanda pouco esforço para os seres humanos, sendo tão natural que nem notamos o processo e até um bebê, desde muito jovem, é capaz de reconhecer, sem exitar, a própria mãe entre outras pessoas nas proximidades.

Apesar de trivial, em sua abordagem biológica, processos de reconhecimento de padrões mostram-se desafiadores computacionalmente, o melhor identificador de padrões conhecido é, na maioria das situações, o ser humano [1].

O reconhecimento de padrões aborda o estudo de como máquinas podem observar o meio, aprender a distinguir objetos de interesse e tomar decisões. Em um processo de classificação, padrões de entrada são associados, através do processamento de suas características, a uma categoria que possa defini-los num conjunto de elementos com características similares. Este conceito consiste na definição de *classe*. Esta definição representa como padrões podem ser agrupados de acordo com características similares.

O processo de associação entre um padrão e sua classe consiste na análise de ca-

racterísticas. Assim, um padrão irá pertencer a uma classe quando suas características medidas corresponderem às esperadas para determinada classe. Uma abordagem didática consiste em dividir o espaço de características em regiões distintas de classificação para que padrões de mesma classe ocupem uma mesma região e os de classes diferentes pertençam a regiões distintas. Essa abordagem pode ser observada na Figura 1.1 onde as linhas que separam regiões são denominadas *fronteiras de decisão*.

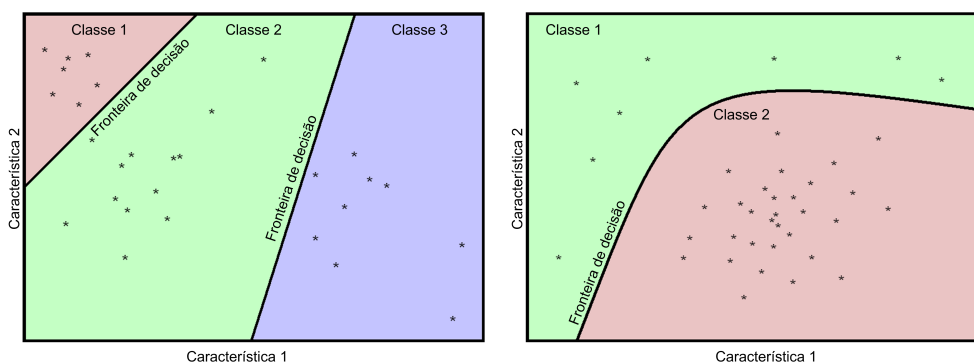


Figura 1.1: Conceito de região de classificação e fronteira de decisão em um espaço de características 2-D, a imagem à esquerda mostra um exemplo de três classes distintas. Observe que, neste caso, a fronteira de decisão é linear. Na figura à direita temos um exemplo onde as regiões de classificação são separadas por uma curva.

Um sistema comum de reconhecimento de padrões é ilustrado na Figura 1.2. Neste diagrama, temos dois ciclos básicos: ciclo de execução, o qual consiste na realização do processo de classificação bem como suas sub-etapas e o ciclo de treino, onde o sistema aprende a associar um padrão a uma determinada classe. Cada um dos blocos de um sistema de reconhecimento de padrões será descrito nas subseções seguintes.

### 1.1.1 Aquisição/Sensoriamento

Afim de um claro entendimento sobre o processo de aquisição, dois conceitos devem ser inicialmente abordados. O primeiro é o processo de amostragem que consiste na medida de um sinal analógico em intervalos definidos de tempo. Neste processo, qualquer medida entre amostras é perdida e a quantidade de informação obtida ao longo do tempo depende especialmente da velocidade em que atuam os conversores. O segundo conceito é o processo de quantização no qual medidas analógicas podem assumir valores discretos, esse processo é dependente da resolução dos conversores analógico-digitais.

Para que padrões sejam classificados devem ser primeiramente coletados. Essa etapa de coleta recebe o nome de aquisição ou sensoriamento, sendo realizada através de sensores os quais convertem as informações físicas de sua forma natural para um

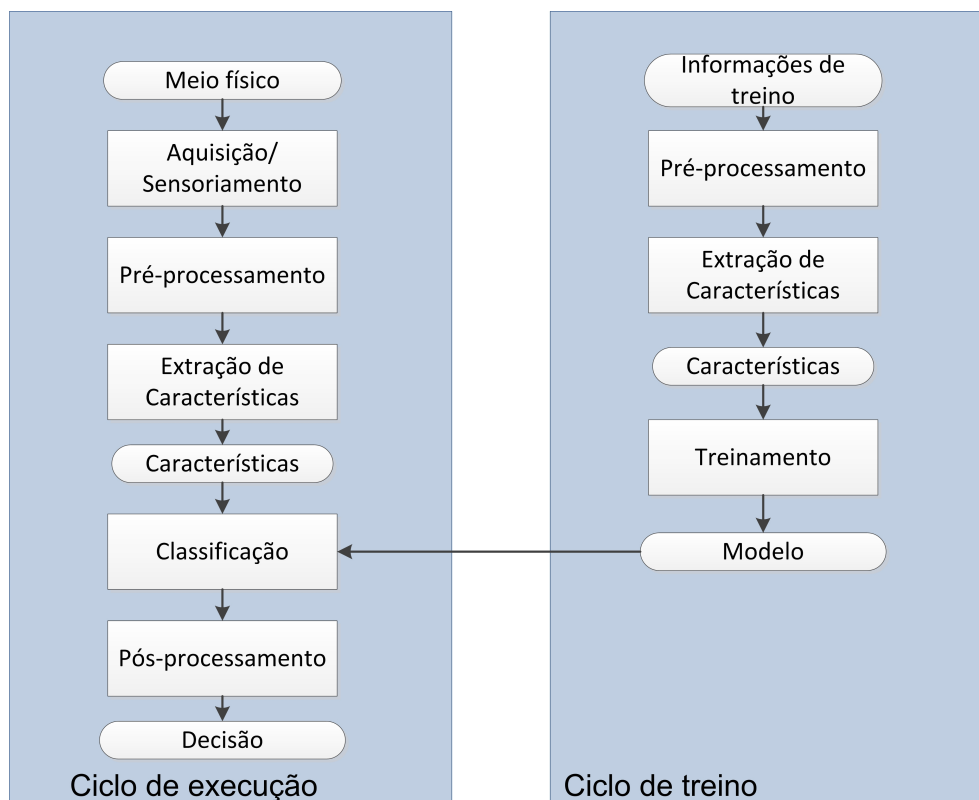


Figura 1.2: Sistema básico de reconhecimento de padrões.

signal (por exemplo, elétrico) o qual é amostrado e quantizado, gerando uma sequência numérica. A Figura 1.3 mostra os efeitos do processo de amostragem e quantização em um sinal analógico.




Figura 1.3: Ilustração do processo de quantização, à esquerda temos um sinal analógico (em Volts) obtido por um sensor, à direita o mesmo sinal amostrado e quantizado.

Dependendo da situação e da natureza do processo de classificação, diversos

tipos de sensores podem ser utilizados, tais como: câmeras, microfones, sensores de toque, iluminação entre outros [22].

### 1.1.2 Pré-processamento

Na maioria das aplicações, o conjunto original das variáveis de entrada costuma ser processado afim de convertê-las em um novo espaço onde, é esperado, seja mais fácil a resolução do problema de reconhecimento de padrões [23]. Mudanças de base, transformações lineares, rotação, translação, normalização, segmentação são todos exemplos típicos de pré-processamento. [22].

### 1.1.3 Extração de Características

Ao observarmos padrões distintos procuramos encontrar as diferenças e semelhanças entre eles para então afirmarmos a que classe cada qual pertence. Uma característica é um atributo, uma qualidade associada ao padrão que permite sua categorização. São exemplos de características: cor, altura, largura, área, volume dentre outros [23], [24].

Matematicamente, costuma-se agregar características em forma vetorial [22, 25] da seguinte maneira:

$$\mathbf{x} = \left( x_1 \quad x_2 \quad \dots \quad x_N \right)^T \quad (1.1)$$

Na equação (1.1), cada  $x_i$  é a característica  $i$  de um total  $N$  características. O subscrito  $T$  representa a transposição do vetor. Na extração de características, medimos valores relevantes para distinção de classes agregando-os em um conjunto que será usado pelo classificador. É importante, no desenvolvimento desta etapa, determinamos quais são os atributos mais relevantes. A Figura 1.4 mostra um exemplo de análise, no espaço de cor RGB, para determinação da melhor característica a ser usado no reconhecimento.

### 1.1.4 Classificação

Nesta etapa, exploram-se as semelhanças e diferenças entre os padrões. Se o sistema for supervisionado, exploramos as características de entrada com os modelos treinados, ao final desta etapa, a classe a qual o padrão pertence é determinada. Quando as funções de densidade probabilidade condicional de cada classe são conhecidas ou podem ser estimadas, o método de classificação Bayes que minimize o risco médio ou a probabilidade de reconhecimento errôneo pode ser derivado [26, 22]. Quando as funções densidade de probabilidade são desconhecidas, métodos não-paramétricos podem ser

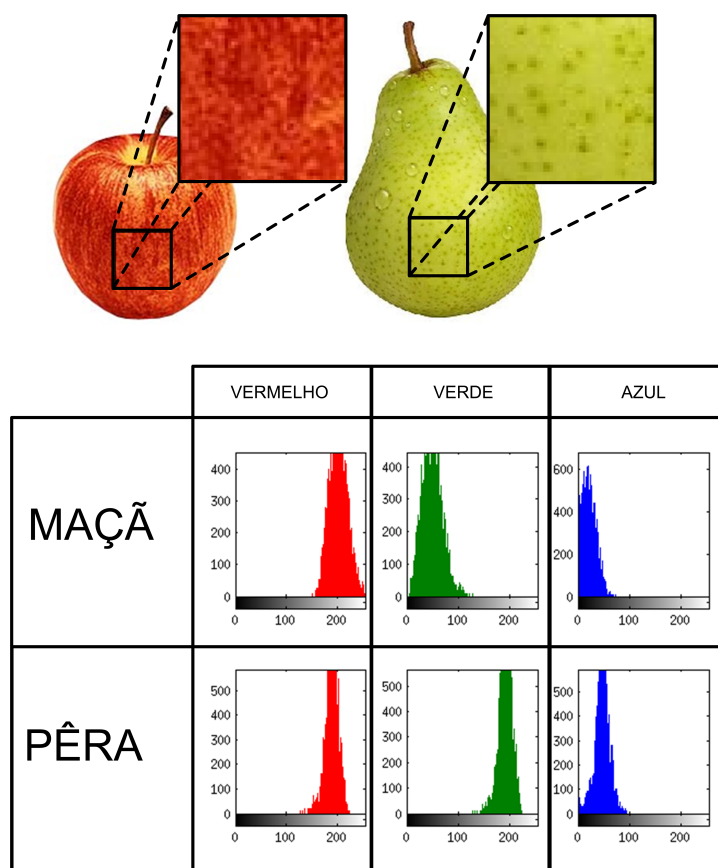


Figura 1.4: Imagem ilustrando uma análise de cor para escolher a melhor característica para ser usada em um classificador. No quadro inferior nota-se que apenas a componente verde já é suficiente para correta categorização.

usados dentre os quais se pode citar: estimadores de densidade de kernel [27, 28, 29]; vizinhança próxima [30, 31]. Classificação por modelos [32, 33, 34] também são maneiras difundidas de classificação e consistem na medida de similaridade entre um padrão de teste e um modelo pré-estabelecido que represente a classe. Com informação inicial suficiente, o classificador poderá tomar decisões com bom desempenho, e informações adicionais podem ser exploradas numa posterior etapa de pós-processamento.

### 1.1.5 Pós-processamento

O processamento adicional, as vezes necessário para melhorias no processo da tomada de decisão, pode ser realizado em uma fase posterior de pós-processamento. Elementos comuns nesta etapa se incluem: a exploração de contexto [35], o uso da medida de confiabilidade dos resultados [22], e combinação de agentes especialistas [36]. A esses processos adicionais realizados afim de melhorar o processo de classificação denomina-se pós-processamento.



### 1.1.6 Treinamento

Num senso amplo, qualquer método que incorpore amostras de treino, no modelo de um classificador, emprega treinamento [22]. Devido a complexidade da maioria dos processos de reconhecimento, torna-se difícil a antecipação de uma decisão. A criação de classificadores envolvem um modelo para estimação e tratamento de padrões diferentes dos utilizados no treino. O objetivo da fase de treinamento é a redução do erro de classificação para um conjunto de entrada. Quanto ao tipo, os modelos de treinamento podem ser classificados em supervisionado, não-supervisionado e treinamento por reforço [22].

Quando cada padrão de treinamento já está associado a uma classe, o treinamento é dito supervisionado [1], ou seja, neste tipo de treinamento os padrões são apresentados com rótulos de classe. A cada ciclo de treino o classificador é ajustado a fim de se reduzir o erro de desclassificação existente entre o valor de saída e o esperado. A estrutura é ilustrada na Figura 1.5.




Figura 1.5: Modelo simplificado do processo de treinamento supervisionado.

Se o rótulo de classe não está presente nos padrões de treino temos *treinamento não-supervisionado* [22]. Um exemplo desse tipo de sistema é o processo de agrupamento, ilustrado na Figura 1.6, no qual os dados de treinamento não contêm um valor esperado de saída, a semelhança de regiões é usada para a determinação das respectivas classes. São exemplos de agrupamentos: identificação de diferentes texturas em uma imagem [37] e reconhecimento de áreas urbanas e rurais em fotos de satélite [38].

No treinamento por reforço [23] um padrão é apresentado sem uma saída esperada. É bem similar ao treinamento supervisionado e sua estrutura é mostrada na Figura 1.7.




Figura 1.6: Exemplo de agrupamento.

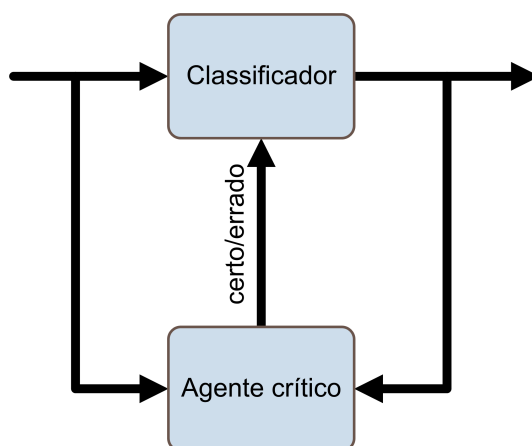


Figura 1.7: Modelo simplificado do processo de treinamento por reforço.

## 1.2 Transformada Rápida de *Fourier* (FFT, *Fast Fourier Transform*)

A Transformada de *Fourier* é uma das mais importantes ferramentas em análise de sinais, possibilitando o entendimento e a realização de sistemas no domínio espectral [39]. A Transformada de *Fourier*,  $X(f)$ , é expressa por:

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (1.2)$$

Na equação (1.2) temos que:  $x(t)$  é uma função contínua no domínio temporal,  $X(f)$  é sua representação no domínio da frequência e  $j$  é um número completo.

A Transformada de *Fourier* pode ser obtida para sinais temporais discretos [1].

Pode-se expressar a forma discreta da Transformada de *Fourier* através da expressão:

$$\begin{aligned} X(k) &= \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi kn}{N}} \\ &= \sum_{n=0}^{N-1} x(n) W_N^{kn}, \quad (0 \leq k \leq N-1) \end{aligned} \quad (1.3)$$

Esta formulação, apresentada na equação (1.3), é denominada por *Transformada de Fourier Discreta* (DFT, do inglês *Discrete Fourier Transform*). Uma representação discretizada no domínio da frequência,  $X(k)$ , é obtida a partir de uma sequência temporal discreta  $x(n)$ . O termo  $W_N$  é igual a  $e^{-j\frac{2\pi}{N}}$ .

Similarmente, a equação da transformada inversa é expressa por:

$$\begin{aligned} x(n) &= \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j\frac{2\pi kn}{N}} \\ &= \frac{1}{N} \sum_{k=0}^{N-1} X(k) W_N^{-kn}, \quad (0 \leq n \leq N-1) \end{aligned} \quad (1.4)$$

Podemos calcular a DFT de maneira eficiente utilizando um algoritmo rápido [40] denominado por FFT (*Fast Fourier Transform*). Este algoritmo pode ser obtido como segue: supondo que  $N$  seja uma potencia exata de 2, ou seja,  $N = 2^l$ . Agora separando o somatório da equação (1.3) em uma parte par e outra ímpar, temos:

$$\begin{aligned} X(k) &= \sum_{n=0}^{N-1} x(n) W_N^{kn} \\ &= \sum_{n=0}^{\frac{N}{2}-1} x(2n) W_N^{2nk} + \sum_{n=0}^{\frac{N}{2}-1} x(2n+1) W_N^{(2n+1)k} \\ &= \sum_{n=0}^{\frac{N}{2}-1} x(2n) W_N^{2nk} + W_N^k \sum_{n=0}^{\frac{N}{2}-1} x(2n+1) W_N^{2nk} \end{aligned} \quad (1.5)$$

Sendo  $N$  um número par:

$$W_N^{2nk} = e^{-j(\frac{2\pi nk}{N})2nk} = e^{-j(\frac{2\pi}{N})nk}$$

A equação (1.5) pode ser reescrita por:

$$X(k) = \sum_{n=0}^{\frac{N}{2}-1} x(2n) W_{\frac{N}{2}}^{nk} + W_N^k \sum_{n=0}^{\frac{N}{2}-1} x(2n+1) W_{\frac{N}{2}}^{nk} \quad (1.6)$$

Note-se o fato de o primeiro somatório ser a DFT das amostras pares e o segundo somatório DFT das amostras ímpares multiplicado pelo fator  $W_N^k$ . O processo segue sendo repetido, recursivamente, até o componente mais elementar, nesse caso quando os somatórios se reduzem a dois elementos. Esse algoritmo de fatoração é chamado RADIX-2 e o processo completo, para  $N = 8$ , é ilustrado na Figura 1.8.




Figura 1.8: Algoritmo RADIX-2 para uma transformada de 8 pontos.

### 1.3 Análise de Componentes Principais

A Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*) ou Transformada de Karhunen-Loève (KLT) [41] é um método estatístico usado, principalmente, na redução de dimensionalidade de dados [42]. Esta transformada apresenta, como característica interessante, o fato de que durante a redução

dimensional das amostras de entrada o ruído é diminuído visto que o mesmo contribui pouco nas componentes principais, [2]. A formulação matemática para a PCA pode ser obtida como segue: supondo um conjunto de  $m$  vetores  $n$ -dimensionais  $\mathbf{x}_i$ , com  $i = \{1, 2, \dots, m\}$ , o vetor média é calculado da seguinte maneira:

$$\boldsymbol{\mu} = \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i \quad (1.7)$$

A matriz de covariância  $\mathbf{X}$  pode ser obtida por:

$$\mathbf{X} = \frac{1}{m} \sum_{i=1}^m (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T \quad (1.8)$$

O passo chave da PCA é a determinação dos autovalores,  $\lambda_i$ , e dos respectivos autovetores,  $\mathbf{v}_i$ , da matriz de covariância. Quando  $n \gg m$ , o algoritmo de decomposição de valores singulares (SVD) [43] pode ser usado para obtenção computacional de  $\lambda_i$  e do respectivo vetor  $\mathbf{v}_i$ . Assim os vetores ortogonais,  $\mathbf{u}_i$ , podem ser escolhidos da seguinte maneira:

$$\mathbf{u}_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{X} \mathbf{v}_i, (i = 1, 2, \dots, l) \quad (1.9)$$

A base ortogonal  $\mathbf{A} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_l)$ , pode ser obtida e, através da projeção dos vetores originais, obtêm-se as componentes principais  $\mathbf{y}_i$ . Esta formulação pode ser obtida como segue:

$$\mathbf{y}_i = \mathbf{A}^T \mathbf{x}_i, (i = 1, 2, \dots, l) \quad (1.10)$$

## 1.4 O Algoritmo *k-means*

O termo *k-means* foi primeiramente usado em 1967 [44] sendo uma ideia que remonta 1956 [45], o algoritmo consiste num método de agrupamento (clusterização ou particionamento) no qual um dado conjunto de observações ( $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ ), onde cada uma corresponde a um vetor  $d$ -dimensional, é agrupado em  $k$  conjuntos gerando um conjunto solução  $S = \{s_1, s_2, \dots, s_k\}$  sendo  $k \leq n$  no qual cada observação está contida em sua respectiva partição  $s_1, s_2, \dots, s_k$ .

O algoritmo atua minimizando a soma dos quadrados em relação a média da partição (observe a Figura 1.9). Resumidamente, o algoritmo inicia com  $k$  centroides. Cada observação é agregada à partição cujo centroide está mais próximo, os centroides de cada partição são recalculados e o processo se repete até que haja convergência. Esse algoritmo é de fácil implementação e algumas variações se fazem presentes na literatura [46, 47] no sentido de acrescentar heurísticas para sua otimização e também

Figura 1.9: Algoritmo *k-means*

melhorar a determinação dos centroides iniciais [48].

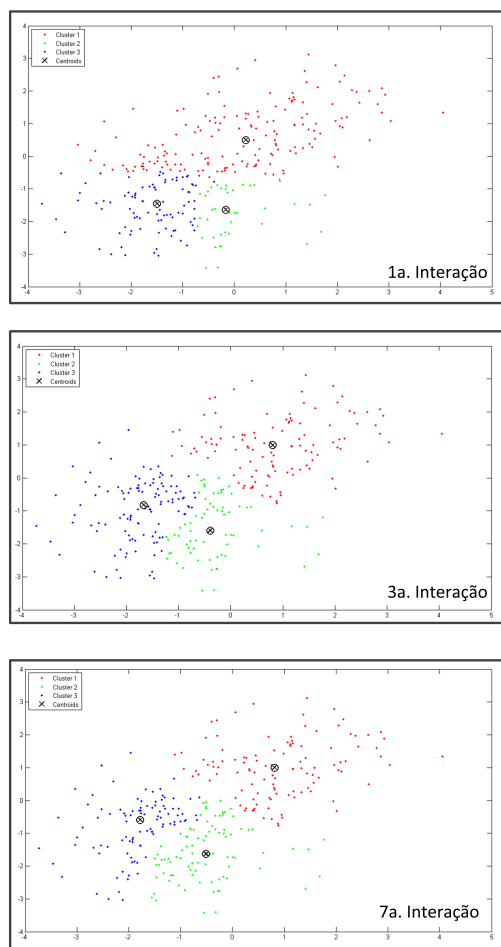


Figura 1.10: Exemplo ilustrativo de algumas iterações do algoritmo *k-means*, atentar ao fato do centroide se mover a cada iteração sendo que na sétima ocorre convergência.

# Capítulo 2

## Reconhecimento de Padrões por Correlação

Neste capítulo, trataremos de métodos específicos utilizados em nosso trabalho. Nosso objetivo é descrever alguns métodos que utilizam filtros de correlação e explicitar como são formulados matematicamente. A organização do capítulo é feita como segue: primeiramente, apresentamos uma breve introdução a cerca da teoria clássica de filtragem por correlação. Posteriormente, apresentamos a formulação matemática para a Função Discriminante Sintética e para os filtros com Minimização da Média de Energia de Correlação.

### 2.1 Introdução

A tarefa de reconhecer padrões através de filtros de correlação pode ser interpretada como um problema de classificação por modelo [25]. Neste caso, a classificação consiste em determinar qual padrão de teste combina melhor com um padrão de referência (modelo). Matematicamente [14], a correlação contínua é expressa de forma simples, começando-se com duas funções  $t(\bullet)$  e  $h(\bullet)$ , determinamos a função  $c(\bullet)$  como segue:

$$c(x) = \int_{-\infty}^{\infty} t(\tau)h^*(x + \tau)d\tau \quad (2.1)$$

A equação (2.1) define a correlação  $c(x)$ . Esta é uma medida estatística de similaridade entre duas variáveis aleatórias. A variável  $t$  representa um padrão candidato,  $h$ , corresponde a um modelo (neste caso denominado filtro de correlação) esperado de  $t$  e  $c$  corresponde a medida de correlação entre o padrão candidato e o seu respectivo modelo. O estudo dos filtros de correlação proporcionou o surgimento de uma sub-área de Reconhecimento de Padrões denominada por Reconhecimento de Padrões por



Correlação (CPR, do inglês *Correlation Pattern Recognition*) [14].

O processo de correlação cruzada discreta de uma imagem de teste  $t(m, n)$ , e um modelo  $h(m, n)$ , produz uma imagem bi-dimensional com picos de energia nos pontos de maior correspondência entre ambos. Esse processo pode ser feito tanto no domínio do tempo quanto no domínio da frequência, a vantagem de sua execução no domínio da frequência reside no fato do sistema adquirir imunidade ao deslocamento. Utilizando a correlação cruzada discreta, expressa por:

$$c(m, n) = \sum_k \sum_l t(m, n)h(k + m, l + n) \quad (2.2)$$

Podemos utilizar uma janela deslizante por bloco e calcular a correlação cruzada discreta, expressa na equação (2.2), para cada deslocamento. Como resultado, temos uma imagem conforme ilustrado na Figura 2.1.



Figura 2.1: Esquema de correlação de imagens.

Esquema de correlação de imagens: imagem de entrada, modelo e saída (na sequência:  $t$ ,  $h$  e  $c$ ).

Similarmente, podemos expressar a correlação no domínio da frequência, através da Transformada de *Fourier* discreta (DFT). Matematicamente, a expressão que utiliza filtros de correlação no domínio da frequência é dada por:

$$\mathbf{C} = DFT^{-1}(\mathbf{H}^* \cdot DFT(\mathbf{t})) \quad (2.3)$$

Observe que na equação (2.3) temos as transformadas de *Fourier* discreta de  $h$  e  $t$  e a operação de produto. A Figura 2.2 ilustra visualmente o processo.

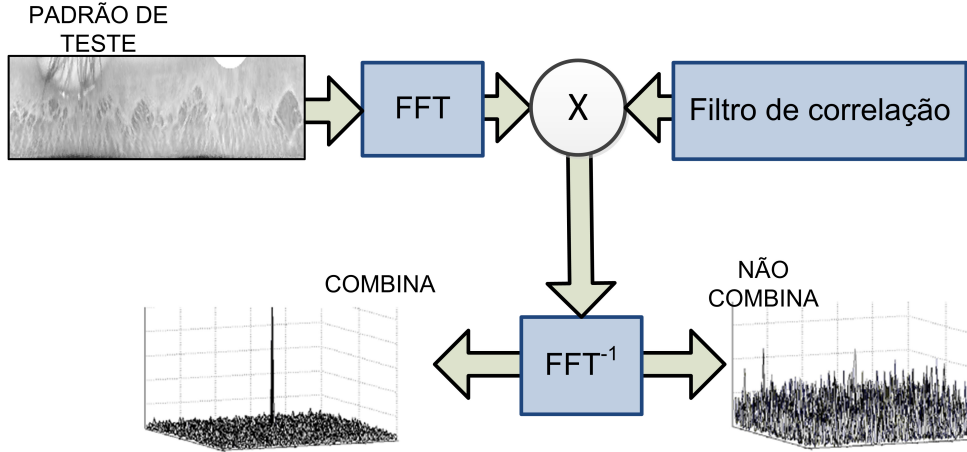


Figura 2.2: Modelo de Classificador usando filtros de correlação

## 2.2 Função Discriminante Sintética

A Função Discriminante Sintética (SDF, do inglês *Synthetic Discriminant Function*) [49] consiste em uma variação dos filtros casados projetada de forma a se gerar um modelo composto pela combinação linear das imagens de treino [20]. Apesar de bem conhecido, apresenta como pontos fracos a necessidade de centralização e o controle limitado dos picos de correlação, de fato, apenas a origem é controlada e são bem comuns situações onde lóbulos laterais superam o valor da origem levando a falsa detecção. Sua variância ao deslocamento, entretanto, pode ser superada através do uso da componente de magnitude espectral das imagens de teste e treino. A transformada discreta de *Fourier* tem apenas a componente de fase alterada em consequência à deslocamentos no domínio temporal [50].

O filtro SDF,  $h(m, n)$ , é projetado de forma a se obter um determinado valor de pico,  $u_i$ , para cada imagem de treino,  $x_i(m, n)$ , na origem do respectivo plano de correlação,  $g_i(m, n)$ . Dessa forma, o filtro poderá ser projetado para retornar um valor de pico distinto para cada classe de treino. O valor de pico é expresso por:

$$u_i = g_i(0, 0) = \sum_{m=1}^{d_1} \sum_{n=1}^{d_2} x_i(m, n)h(m, n), (1 \leq i \leq N). \quad (2.4)$$

Na equação (2.4) temos que  $N$  corresponde a quantidade imagens de treino e  $d_1$  e  $d_2$  o número de linhas e colunas, respectivamente, em cada imagem. Convertendo  $x_i$  e  $h$  em forma vetorial, a equação (2.4) pode ser simplificada da seguinte forma:

$$u_i = \mathbf{x}_i^T \mathbf{h}, (1 \leq i \leq N) \quad (2.5)$$

Combinando as equações (2.4) e (2.5) em uma única equação matricial, obtemos:

$$\mathbf{u} = \mathbf{X}^T \mathbf{h} \quad (2.6)$$

onde:  $\mathbf{X} = \begin{pmatrix} \mathbf{x}_1 & \mathbf{x}_2 & \dots & \mathbf{x}_N \end{pmatrix}$  e  $\mathbf{u} = \begin{pmatrix} u_1 & u_2 & \dots & u_N \end{pmatrix}^T$ . Sendo  $d$  o número de pontos de uma imagem de treino e  $N \ll d$ , para que uma única solução de  $\mathbf{h}$  seja encontrada, devemos tomar  $\mathbf{h}$  como sendo uma combinação linear do conjunto de treino  $\mathbf{X}$  e  $\mathbf{a}$  como o vetor de coeficientes dessa combinação linear. Isto pode ser expressado da seguinte maneira:

$$\mathbf{h} = \mathbf{X}\mathbf{a} \quad (2.7)$$

Para determinarmos o vetor de coeficiente  $\mathbf{a}$ , substituímos a equação (2.7) na equação (2.6) e assim obtemos:

$$\mathbf{a} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{u} \quad (2.8)$$

Por fim, ao se substituir  $\mathbf{a}$  (obtido na equação (2.8)) na equação (2.7), obtemos a solução para o filtro SDF, conforme a seguir:

$$\mathbf{h} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{u} \quad (2.9)$$

## 2.3 Filtro de Correlação MACE

O filtro de correlação MACE (do inglês, *Minimum Average Correlation Energy*) [51], [52] tem como objetivo reduzir os lóbulos laterais elevados presentes no filtro SDF (Seção 2.2). Para tal, utilizamos a minimização da média da energia de correlação. A média da energia de correlação (ACE, do inglês *Average Correlation Energy*) para  $N$  imagens de treino é definida por:

$$ACE = \frac{1}{N} \sum_{i=1}^N \sum_m^{d_1} \sum_n^{d_2} |g_i(m, n)|^2 \quad (2.10)$$

onde  $g_i$  é o  $i$ -ésimo plano de correlação resultante. Usando o teorema de Parseval [53], o parâmetro ACE pode ser expresso no domínio da frequência conforme segue:

$$ACE = \frac{1}{dN} \sum_{i=1}^N \sum_k^{d_1} \sum_l^{d_2} |G_i(k, l)|^2 \quad (2.11)$$

onde:  $G_i(k, l)$  é a transformada de Fourier 2-D de  $g_i(m, n)$ . Como  $G_i(k, l) = H(k, l)X_i^*(k, l)$  a expressão, no domínio da frequência se torna:

$$ACE = \frac{1}{dN} \sum_{i=1}^N \sum_k^{d_1} \sum_l^{d_2} |H(k, l)|^2 |X_i(k, l)|^2 \quad (2.12)$$

Uma forma de simplificar a análise é expressar  $H(k, l)$  como um vetor,  $\mathbf{h}$ , e definir uma matriz diagonal,  $\mathbf{X}_i$ , na qual os elementos na diagonal principal correspondem à  $X_i(k, l)$ , assim a equação para o parâmetro ACE se torna:

$$\begin{aligned} ACE &= \frac{1}{dN} \sum_{i=1}^N (\mathbf{h}^H \mathbf{X}_i) (\mathbf{X}_i^* \mathbf{h}) \\ &= \mathbf{h}^H \left[ \frac{1}{dN} \sum_{i=1}^N \mathbf{X}_i \mathbf{X}_i^* \right] \mathbf{h} \\ &= \mathbf{h}^H \mathbf{D} \mathbf{h} \end{aligned} \quad (2.13)$$

onde:  $\mathbf{D} = \frac{1}{dN} \sum_{i=1}^N \mathbf{X}_i \mathbf{X}_i^*$  é uma matriz diagonal de tamanho  $d \times d$ .  $\mathbf{X}_i$  contém em sua diagonal a  $i$ -ésima coluna de  $\mathbf{X}$ .

Através da minimização da média da energia de correlação (ACE), esperamos uma redução de lóbulos laterais e picos de correlação melhor definidos. Para finalizar a análise, as condições de restrição também devem ser expressas no domínio da frequência, tendo em vista o fato de um produto interno no domínio espacial ser diretamente proporcional ao produto interno no domínio da frequência, obtemos então a seguinte equação:

$$\mathbf{X}^H \mathbf{h} = d\mathbf{u} = \mathbf{c} \quad (2.14)$$

na qual:  $\mathbf{X}$  é a matriz onde cada coluna,  $\mathbf{x}_i$  corresponde a representação vetorial da Transformada de *Fourier* da  $i$ -ésima imagem de treino.

Usando-se o método de Lagrange, o gradiente termo quadrático da equação (2.13) pode ser expresso de forma a satisfazer as condições de restrição da equação (2.14):

$$\Phi = \mathbf{h}^H \mathbf{D} \mathbf{h} - 2\lambda_1 (\mathbf{x}_1^H \mathbf{h} - c_1) - 2\lambda_2 (\mathbf{x}_2^H \mathbf{h} - c_2) - \dots - 2\lambda_M (\mathbf{x}_M^H \mathbf{h} - c_M) \quad (2.15)$$

onde os parâmetros  $\lambda_1, \lambda_2, \dots, \lambda_M$  são os multiplicadores de Lagrange. Fazendo o gradiente  $\Phi$  com relação à  $\mathbf{h}$  igual a zero, temos:

$$2\mathbf{D}\mathbf{h} - 2(\lambda_1 \mathbf{x}_1 + \lambda_2 \mathbf{x}_2 + \dots + \lambda_M \mathbf{x}_M) = 0 \quad (2.16)$$

Definindo  $\mathbf{m} = (\lambda_1 \ \lambda_2 \ \dots \ \lambda_M)^T$ , a equação (2.16) pode ser expressa como:

$$\mathbf{D}\mathbf{h} - \mathbf{X}\mathbf{m} = 0 \quad (2.17)$$

ou seja, temos que:

$$\mathbf{h} = \mathbf{D}^{-1}\mathbf{X}\mathbf{m} \quad (2.18)$$

Substituindo a equação (2.18) na equação (2.14) temos:

$$\mathbf{X}^H\mathbf{D}^{-1}\mathbf{X}\mathbf{m} = \mathbf{c} \quad (2.19)$$

Assim obtemos a seguinte solução para matriz  $\mathbf{m}$  de multiplicadores de Lagrange:

$$\mathbf{m} = (\mathbf{X}^H\mathbf{D}^{-1}\mathbf{X})^{-1}\mathbf{c} \quad (2.20)$$

Por fim, substituindo a equação (2.20) na equação (2.18), obtemos a solução para o filtro de correlação com parâmetro ACE ótimo, através da expressão:

$$\mathbf{h} = \mathbf{D}^{-1}\mathbf{X}(\mathbf{X}^H\mathbf{D}^{-1}\mathbf{X})^{-1}\mathbf{c} \quad (2.21)$$

A Figura 2.3 é um exemplo ilustrativo de uma típica saída produzida por um filtro MACE quando o padrão de teste apresenta boa correlação com os padrões de treino, nessa figura se pode observar a baixa energia média de correlação e o pico bem definido denotando uma detecção positiva.




Figura 2.3: Exemplo de saída obtida com um filtro MACE.

## Capítulo 3

# Filtros de Correlação SDF e MACE utilizando Análise de Componentes Principais

O fato da Análise de Componentes Principais (PCA) oferecer uma representação ótima das variações presentes em um conjunto de dados faz dela um objeto de estudo interessante na medida que extrair a informação relevante de um conjunto de dados é um passo de grande relevância para a obtenção de um bom modelo. Nesse sentido, podemos utilizar a PCA para modificar a formulação matemática de filtros de correlação. Nesta dissertação em particular, estamos interessados em investigar a formulação matemática dos filtros SDF e MACE quando são projetados utilizando-se a PCA. Para avaliar o desempenho desta proposta, os filtros modificados serão utilizados em um problema de reconhecimento de faces. Ao longo deste capítulo, iremos descrever o projeto do filtro e suas principais características e a descrição dos procedimentos experimentais utilizados na dissertação.

### 3.1 Filtros de Correlação por Função Discriminativa Sintética e Análise de Componentes Principais (SDF-PCA)

Os filtros de correlação por Função Discriminativa Sintética (SDF), descritos na Seção 2.2, apresentam limitações quanto ao controle dos picos de correlação do sinal filtrado. Além disso, os filtros SDF possuem resposta variante ao deslocamento, isso impacta em resultados imprecisos quando os mesmos são utilizados para classificação. Um dos problemas é relacionado a variância em relação ao deslocamento que pode afetar

a resposta do filtro quando o sinal de interesse apresenta alguma rotação angular. Essa característica indesejada pode ser tratada através do uso da transformada de *Fourier* (Seção 1.2). Neste caso, consideramos apenas a componente de magnitude do sinal transformado. Dessa forma, as componentes principais podem ser incorporadas se utilizamos a Equação (2.9) na qual substituímos  $X$  por  $\hat{X}$  e  $\mathbf{u}$  por  $\hat{\mathbf{u}}$  obtendo assim a Equação (3.1).

$$\mathbf{h} = \hat{\mathbf{X}}(\hat{\mathbf{X}}^T \hat{\mathbf{X}})^{-1} \hat{\mathbf{u}} \quad (3.1)$$

onde as colunas de  $\hat{\mathbf{X}}$  correspondem às componentes principais da componente de magnitude da FFT dos padrões de treino. O vetor  $\hat{\mathbf{u}}$ , por sua vez, é o resultado esperado quando uma determinada componente é detectada.

Note que a saída do sistema é determinada pelo produto interno de  $\mathbf{h}$  determinado na Equação (3.1), com um padrão candidato. Dessa forma, a resposta do sistema será maior quanto maior a correlação entre os padrões candidatos e as componentes principais do padrão usado. Ao determinarmos a resposta esperada para cada classe (pode ser feito através de uma simples média), o processo de classificação fica reduzido a determinação da menor distância Euclidiana entre a resposta obtida para cada filtro e a resposta esperada para cada classe.

## 3.2 Filtros de Mínima Energia Média de Correlação com Análise de Componentes Principais (MACE-PCA)

A Equação (2.21) é a solução para o filtro MACE. Uma maneira de aplicar PCA é substituímos cada uma das colunas da matriz  $X$  pela componente principal de maior variância para aquela classe. Os mesmos ajustes devem ser realizados em  $c$ . Ao realizar essa operação, reduz-se o número de padrões envolvidos e as suas variações. O processo de detecção de padrões através do uso de filtros de correlação consiste em especial na detecção de picos de energia no plano de correlação. Assim, resta a pergunta: De que forma o uso da PCA para representar padrões de treino afetaria a resposta obtida no plano de correlação? A Figura 3.1 ilustra dois gráficos, um obtido usando um filtro MACE tradicional e outro mostrando a resposta ao mesmo padrão de um filtro MACE projetado usando apenas a primeira componente principal.

Após observada a produção de picos de energia também em filtros projetados para reagir apenas a primeira componente principal, resta estabelecer uma métrica eficiente para expressar quando um pico de energia ocorre.




Figura 3.1: Exemplo de saídas obtidas com filtros MACE, à esquerda filtro tradicional, à direita resposta a um filtro MACE projetado para a primeira componente principal dos padrões de treino. Observar uma redução no valor de pico sem entretanto afetar significativamente a distinção deste em relação ao ruído lateral.

### 3.2.1 Métrica de detecção de picos de correlação

A detecção de picos é essencial no processo de classificação através do uso de filtros MACE. O problema chave na detecção de picos é que os mesmos podem ocorrer com diferentes amplitudes e escalas, o que pode resultar em uma razoável quantidade de erros de classificação. Duas métricas foram utilizadas na detecção de picos de energia no plano de correlação. Uma consiste em verificar a similaridade entre um modelo de pico e o resultado obtido no processo de filtragem. Essa medida de similaridade é expressa pelo coeficiente de correlação,  $\rho$ , [54], ilustrado na Equação (3.2) e expresso por  $r$ , na Equação (3.3), quando uma amostra for tratada.

$$\rho_{X,Y} = \frac{E[(X - \mu_X)(X - \mu_Y)]}{\sigma_X \sigma_Y} \quad (3.2)$$

onde:  $X$  e  $Y$  são variáveis aleatórias de médias  $\mu_X$  e  $\mu_Y$  respectivamente.

$$r_{X,Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3.3)$$

onde:  $\bar{X}$  e  $\bar{Y}$  correspondem a média das  $n$  amostras de ambas as variáveis e  $X_i$  e  $Y_i$  são as respectivas  $i$ -ésimas amostras de um total de  $n$ .

O coeficiente de correlação tem uma interpretação geométrica na qual ele nada mais é do que o cosseno do ângulo formado por dois vetores, 3.2.






Figura 3.2: Definição geométrica do conceito de coeficiente de correlação.

Definida essa métrica, resta especificar o padrão de referência ao qual a medida de correlação será tomada. Instintivamente se imagina um impulso com sendo um bom candidato, entretanto, é incomum a saída de correlação apresentar um pico de energia tão bem definida. Dessa forma, um modelo de picos de energia para a classificação positiva precisa ser estabelecido e esse modelo é conseguido através do cálculo de média da saída obtida em vários experimentos nos quais é esperado um pico de energia. Em outras palavras, sendo  $C_k(i, j)$  uma resposta  $k$  positiva (onde modelo combina com padrão de teste) de um total de  $n$ , temos o modelo de saída expresso como a média das saídas obtidas esperadas conforme mostrado na Equação (3.4).

$$\bar{C}(i, j) = \sum_{k=1}^n \frac{C_k(i, j)}{n} \quad (3.4)$$

onde  $\bar{C}$  é nossa estimativa de como um pico de energia no plano de correlação deve parecer sendo ilustrado na Figura 3.3.

A segunda métrica adotada consiste na relação entre o nível do pico de energia e o desvio padrão do resultado da energia no plano ACE. Tendo em vista que o processo de filtragem MACE tenta reduzir ao máximo a energia presente no plano de correlação é natural esperar que um bom resultado positivo de classificação apresente um elevado pico de energia e uma baixa oscilação no plano ACE. Essa relação é definida como segue:

$$P_r = \frac{C_{\max}}{\sigma} \quad (3.5)$$

onde:  $P_r$  é o valor da relação entre pico ( $C_{\max}$ ) e desvio padrão ( $\sigma$ ) do vetor de correlação.

Para avaliar um pico potencial de energia é necessário que se realizem as seguintes etapas:

- Realizar a operação de correlação entre o padrão de teste e o modelo, conforme ilustrado na Figura 2.2;




Figura 3.3: Modelo de pico de energia obtido através de média.

- Usar a Equação (3.3) para determinar a similaridade entre o resultado do processo de correlação obtido no item anterior e o modelo de referência ilustrado na Figura 3.3;
- Avaliar o resultado e determinar se ocorreu uma detecção positiva ou não.

### 3.2.2 Métrica de Classificação usada nos filtros MACE

Na Subseção 3.2.1 foi definido o parâmetro medido a ser usado na detecção de um pico de energia, ou seja, a medida do coeficiente de correlação entre o resultado e a saída do filtro de MACE. Entretanto, falta uma definição do quão adequado esse parâmetro é para classificação. Considerando-se um comportamento que siga uma distribuição normal, uma abordagem para quantizar a adequação do parâmetro ao processo de classificação consiste em quantizar o grau de intersecção das distribuições normais obtidas para situações onde a classificação deve ser negativa (padrão de teste não pertence a classe do filtro) e quando a mesma deve ser positiva, tal processo é ilustrado na Figura 3.4.

Uma maneira de realizar tal estimativa é através do coeficiente de sobreposição [55] (OVC, em inglês *Overlapping Coefficient*) ou através do coeficiente de Bhattacharyya [56]. Para essas métricas, quanto menor o grau de intersecção entre os resultados de rejeição (negativos) e aprovação (positivos) melhor será a qualidade da métrica e menor será o erro de classificação.

Para estimar a área de intersecção, primeiramente calculemos os pontos no eixo  $x$  onde as gaussianas se encontram. Sendo  $\mu_1$ ,  $\sigma_1$ ,  $\mu_2$  e  $\sigma_2$  a média e desvio padrão para a primeira gaussiana e segunda gaussiana respectivamente, podemos calcular os pontos de intersecção descobrindo onde as duas funções se igualam, dessa forma podemos




Figura 3.4: Intersecção entre duas distribuições normais. quanto menor a intersecção entre o conjunto de valores para as classificações negativa e positiva, melhor é o parâmetro para classificação.

iniciar a análise trabalhando a Equação (3.6).

$$\frac{1}{\sigma_1\sqrt{2\pi}}e^{\left(\frac{x-\mu_1}{\sigma_1}\right)^2} = \frac{1}{\sigma_2\sqrt{2\pi}}e^{\left(\frac{x-\mu_2}{\sigma_2}\right)^2} \quad (3.6)$$

Com alguma manipulação matemática obtemos os valores de intersecção entre as duas gaussianas resolvendo a Equação (3.6).

$$x = \left\{ \begin{array}{l} \frac{\sigma_1^2\mu_2 - \sigma_2^2\mu_1 + \sigma_1\sigma_2\sqrt{[2\sigma_2^2\ln(\frac{\sigma_2}{\sigma_1}) - 2\sigma_1^2\ln(\frac{\sigma_2}{\sigma_1}) - 2\mu_1\mu_2 + \mu_1^2 + \mu_2^2]}}{\sigma_1^2 - \sigma_2^2} \\ - \frac{\sigma_2^2\mu_1 - \sigma_1^2\mu_2 + \sigma_1\sigma_2\sqrt{[2\sigma_2^2\ln(\frac{\sigma_2}{\sigma_1}) - 2\sigma_1^2\ln(\frac{\sigma_2}{\sigma_1}) - 2\mu_1\mu_2 + \mu_1^2 + \mu_2^2]}}{\sigma_1^2 - \sigma_2^2} \end{array} \right. \quad (3.7)$$

$$x = \frac{1}{2} \frac{\mu_1^2 - \mu_2^2}{\mu_1 - \mu_2} \quad (3.8)$$

No caso específico em que  $\sigma_1 = \sigma_2$  a Equação (3.6) se reduz á uma equação de primeira ordem e a determinação do único ponto de intersecção é mostrada na Equação (3.8). Obtidos os pontos de intersecção, Equação (3.7), resta agora calcular a área de intersecção das curvas. Para tal, usa-se algum algoritmo numérico e obtemos assim o valor de OVC.

## Capítulo 4

# Sistema de Reconhecimento de Íris utilizando Filtros de Correlação com Análise de Componentes Principais

A fase de desenvolvimento de um classificador também denominada ciclo de projeto, consiste na etapa de concepção e desenvolvimento. O problema de reconhecimento de íris apresenta algumas particularidades que devem ser consideradas durante o processo de desenvolvimento do classificador, destacando-se o reconhecimento individual em condições de cooperação nula ou reduzida e em situações de iluminação adversa e ruidosa.




Figura 4.1: Etapas de desenvolvimento do sistema de classificação proposto.

As etapas de desenvolvimento realizadas nesse processo consistem em: coleta de dados, onde padrões são coletados afim de formar um conjunto relevante de informações a ser usado para treino e teste do classificador; pré-processamento, onde os padrões são normalizados e escalonados; a etapa de seleção de características, onde são exploradas a análise de componentes principais e transformada discreta de *Fourier*; projeto do classificador, onde são usadas as informações obtidas na etapa anterior no desenvolvimento de um modelo de filtro de correlação. As etapas do ciclo de desenvolvimento ilustradas na Figura 4.1 serão abordadas em detalhes no decorrer desse capítulo tendo sempre em mente as particularidades supracitadas no processo de reconhecimento de íris.

## 4.1 Coleta de Dados

A etapa de coleta de dados, também conhecida como aquisição ou sensoria-mento, é a etapa onde as informações para treino e teste são coletadas e se deve tentar assegurar os critérios de adequação e representatividade [22, 57]. A *adequação* garante uma quantidade mínima de informação para o correto treino, não existe regra absoluta, mas uma boa sugestão é que se use 10 vezes o número de instâncias de treino. A *representatividade* assegura que todas as variações prováveis nos padrões que o sistema pode se deparar estão representadas no conjunto de treino e teste, assim sendo, no caso específico do reconhecimento de íris devem-se fazer presentes distorções comuns tais como ruído, foco oclusão e movimento.

Este trabalho não tem como foco a realização da etapa de aquisição de dados, no entanto, para assegurar a melhor satisfação dos critérios de adequação e representatividade adotamos o banco de dados bem estabelecido denominado CASIA-IrisV4 [21].

O banco de dados CASIA-IrisV4 contém 54601 de 1000 indivíduos virtuais e de mais de 1800 indivíduos genuínos. As imagens são geradas usando espectro próximo do infra-vermelho todas em escala de cinza codificadas em 8 bits. Esse banco de dados é composto por 6 subconjuntos de imagens (CASIA-Iris-Interval, CASIA-Iris-Lamp, CASIA-Iris-Twins CASIA-Iris-Distance, CASIA-Iris-Thousand e CASIA-Iris-Syn), cada qual com seu uso e características específicas.

Estatísticas da base CASIA-IrisV4 (subconjunto CASIA-Iris-Interval)	
Modelo de câmera	CASIA close-up iris camera
Ambiente	Interno
Sessões	2
Número de indivíduos	249
Número de classes	395
Número de imagens	2639
Codificação de tom	8 bits
Formato de arquivo	JPEG
Resolução disponibilizada (largura × altura)	320 × 280

Tabela 4.1: Estatísticas do subconjunto CASIA-Iris-Interval.

Apesar dos 6 subconjuntos disponíveis, apenas o CASIA-Iris-Interval foi utilizado neste trabalho por apresentar múltiplas sessões espaçadas por dias, imagens com ruídos e distorções comuns em aplicações reais tais como oclusão, movimento e foco ruim além de uma grande quantidade de classes quando comparado com os subconjuntos restantes compostos por imagens sintéticas, pré-processadas ou previamente selecionadas para apresentarem alta qualidade. As características do CASIA-Iris-Interval




Figura 4.2: Sistema de aquisição usado no subconjunto CASIA-Iris-Interval, imagem da *Chinese Academy of Sciences*.




Figura 4.3: Exemplo de imagens presentes no subconjunto CASIA-Iris-Interval.

são mostradas na Tabela 4.1 e o equipamento de aquisição é mostrado na Figura 4.2 e algumas imagens presentes nesse subconjunto são mostradas na Figura 4.3.

Para finalizar esta seção, resta comentar como o banco de dados escolhido, CASIA-Iris-Interval, se encaixa nos critérios de adequação e representatividade abordados anteriormente por apresentar imagens ricas em detalhes e de qualidade.

## 4.2 Pré-processamento

Nesta etapa, o conjunto de imagens utilizado para treino e teste passa por uma adequação. Apesar da boa tolerância à diversas formas de distorções e ruídos por parte do filtros de correlação, normalização e mapeamento para coordenadas polares são etapas comuns de pré-processamento [17]. A Figura 4.4 mostra os passos adotados nesse trabalho, na Figura 4.5 os resultados das etapas de pré-processamento são ilustrados.




Figura 4.4: Etapas de pré-processamento.




Figura 4.5: Resultado das etapas de pré-processamento.

Tendo em vista a grande quantidade de imagens presentes em cada banco de dados, realizamos a implementação de um código automático para segmentação. Para tal, foram utilizados os processos descritos por Daugman [58] para o banco de dados CASIA-Iris-Interval e o método usado por Luciano [59, 60]. Nos casos em que a segmentação automática não foi efetiva um outro processo de segmentação, agora semi-automático, com uso de operações morfológicas [24] foi utilizado para a detecção automática da pupila e o usuário deveria apenas escolher um ponto na borda exterior da íris para que a segmentação fosse realizada.

Todas as imagens presentes no banco CASIA-Iris-Interval foram normalizadas em  $360 \times 100$  pontos. Um fato interessante a respeito da mudança para o domínio polar é o fato de que rotação no domínio de coordenadas retangulares se tornar um deslocamento no domínio polar. Dessa forma, imunidade a rotação pode ser adquirida no sistema de reconhecimento pelo fato de a operação de correlação cruzada ser invariante ao deslocamento.

### 4.3 Extração de Características

O método utilizado para extração de características neste trabalho consiste na utilização da análise de componentes principais e transformada discreta de *Fourier*. A primeira possibilita a compactação do conjunto de imagens de treino, visto que as primeiras componentes apresentam uma excelente representação da maior parte da variância presente no conjunto de treino, tal efeito é notado na Figura 4.6 onde perceberemos o decréscimo de informação presente em cada componente até ser praticamente nulo na última.




Figura 4.6: Exemplo de resultado obtido através do uso da PCA (componente de maior variância em destaque).

A transformada discreta de *Fourier* (DFT) é útil no sentido de que acrescenta invariância ao deslocamento (teorema do deslocamento) podendo assim ser usada em conjunto com qualquer filtro de correlação de interesse, sendo especialmente útil em combinação com filtros SDF, os quais, necessitam de centralização na origem.

O teorema do deslocamento [61], o qual implica no fato de que um deslocamento espacial equivale a uma mudança de fase no domínio da frequência. Assim, ao deslocarmos uma entrada mantemos a componente modular da DFT, em outras palavras, podemos retirar a influência do deslocamento espacial apenas removendo a componente de fase da DFT. Essa combinação entre PCA e DFT permite uma robustez, em especial quando realizadas em conjunto com o filtro SDF, mais sensível a distorções de deslocamento.



## 4.4 Projeto do Classificador

O classificador usado neste trabalho consiste na combinação das componentes principais em conjunto com o uso dos filtros de correlação. O sistema completo é ilustrado na Figura 4.7, onde se notam duas etapas distintas de realização (treino e teste).

A primeira (Figura 4.7, esquerda) é denominada treino, onde um conjunto de imagens de referência é usada para que se estabeleça uma relação entre as características elementares dos padrões de treino e as respectivas classes as quais pertencem, esse tipo de associação torna possível o desenvolvimento do classificador e ao final dessa etapa é obtido um filtro de correlação a ser usado pelo classificador durante processo de teste subsequente.

A segunda (Figura 4.7, direita) é denominada fase de teste, onde é efetivamente realizada a classificação. Nesta fase, utilizamos padrões de teste, que têm suas características extraídas. Para classificação, utilizamos o filtro de correlação  $h$  gerado no treino. O processo de classificação é realizado pela medida similaridade entre o filtro  $h$  (gerado através do uso das componentes de maior variância do conjunto de treino da respectiva categoria) e o padrão de teste. Para cada classe é gerado um filtro correspondente e assim a classificação pode ser obtida por comparação dos resultado como ilustrado na Figura 4.8.

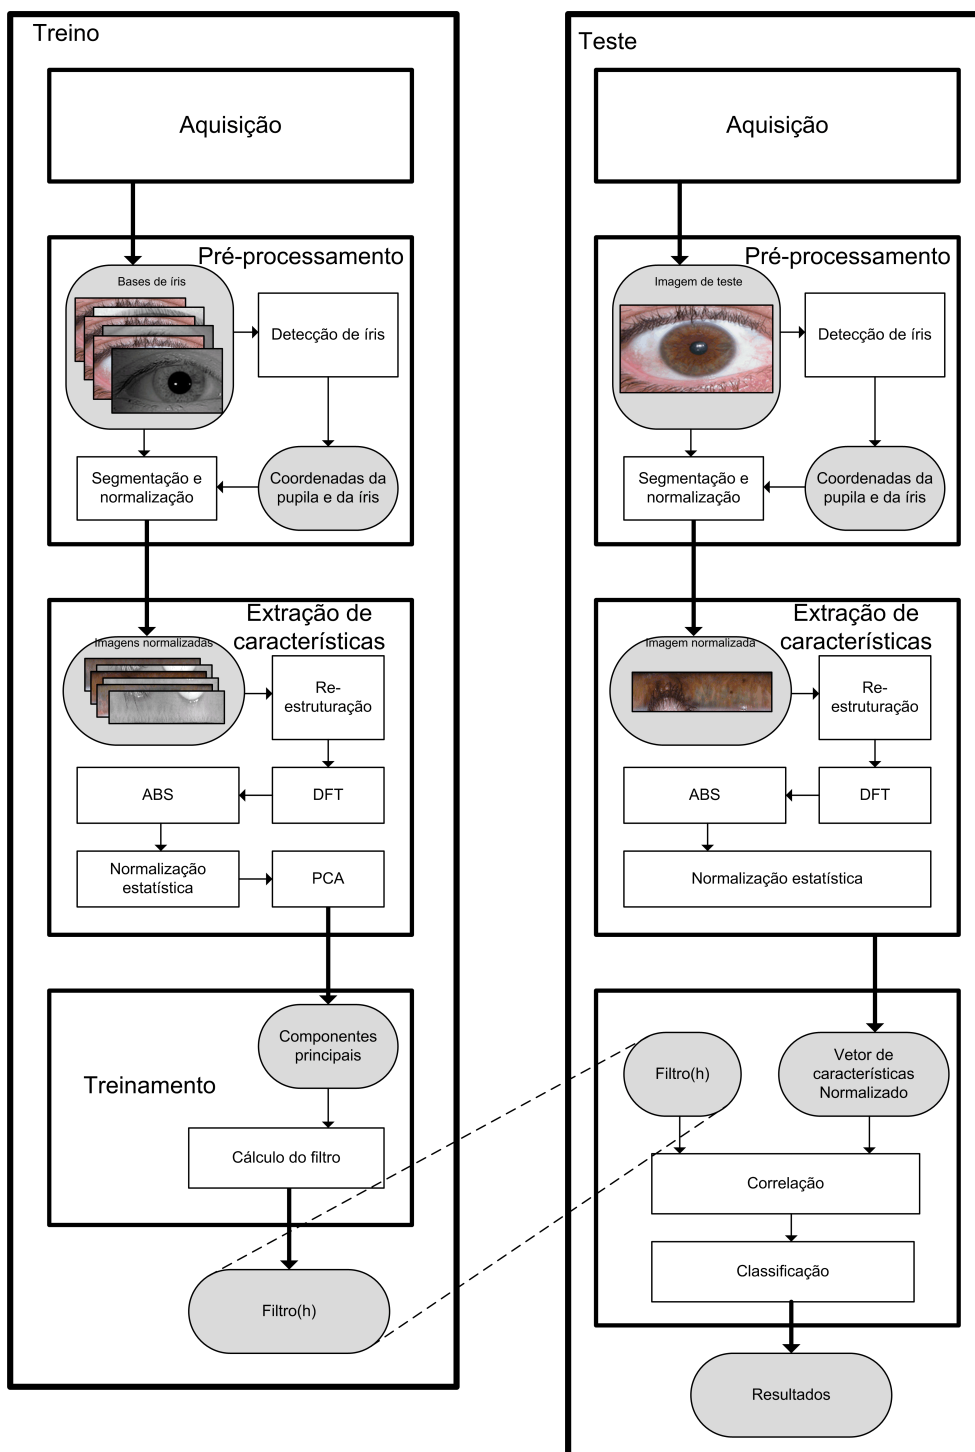


Figura 4.7: Sistema de classificação usado neste trabalho.

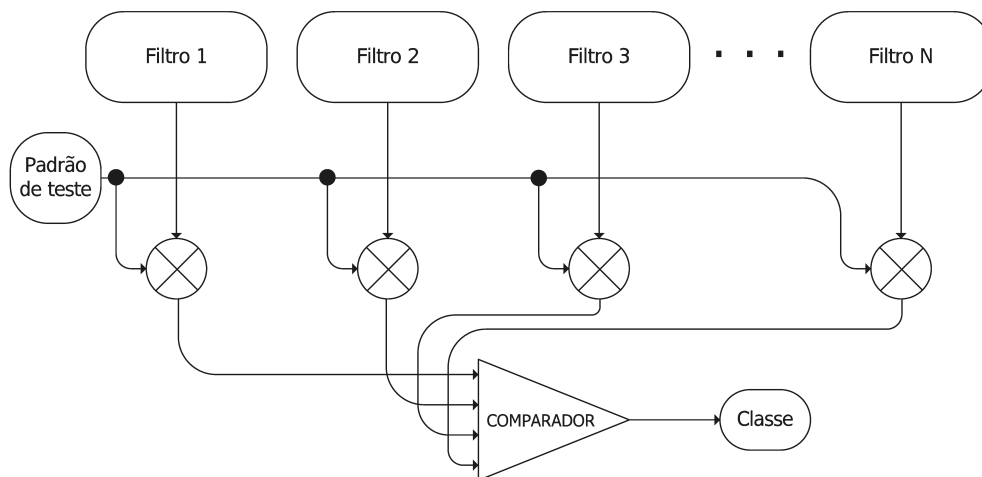


Figura 4.8: Classificação por comparação.

## 4.5 Avaliação de Desempenho

Na avaliação de desempenho, verificamos a capacidade de acerto do classificador em determinadas circunstâncias. Uma forma de fazê-lo consiste em se utilizar um método de validação cruzada, sendo um dos mais comuns o método *k-fold* de validação 4.9. Nesse método, o conjunto total de padrões é dividido em  $k$  grupos, dos quais um grupo é usado para teste e o restante para treino.

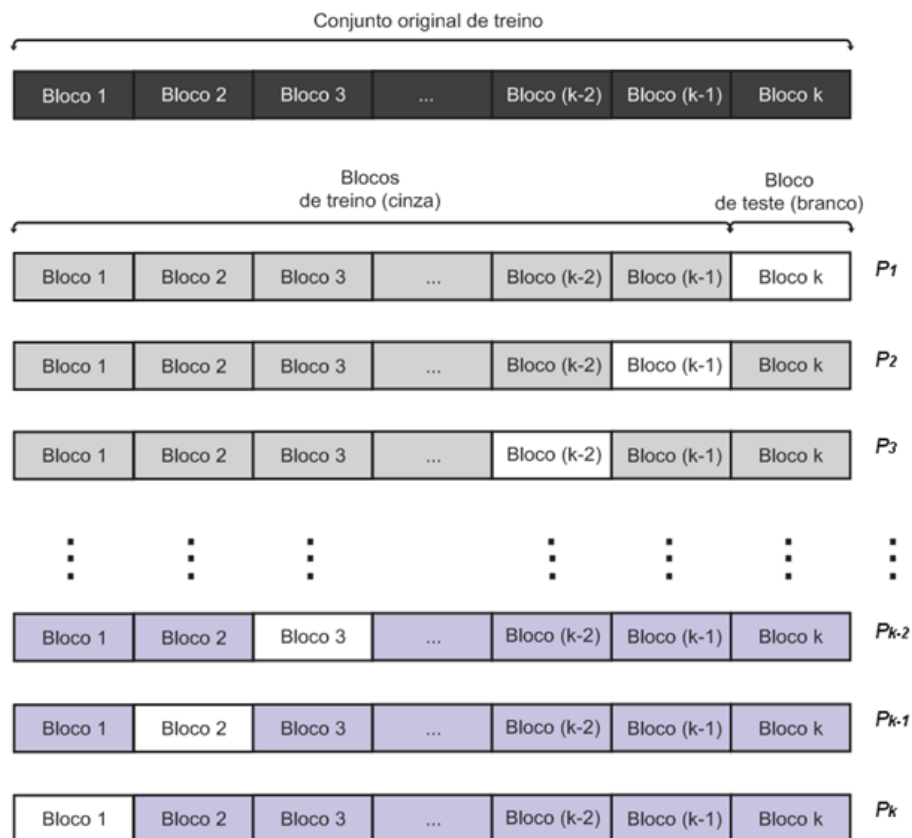


Figura 4.9: Classificação por comparação.

Dessa forma a uma estimativa do desempenho do classificador pode ser obtida na Equação (4.1).

$$\bar{P} = \frac{1}{k} \sum_{t=1}^k P_t \quad (4.1)$$

Um cuidado particular deve ser tomado na escolha de  $k$ , se seu valor for muito grande, mais informação será usada para o treinamento do sistema, entretanto, com a redução do bloco de teste o intervalo de confiança do resultado é reduzido, por outro

lado,  $k$  pequeno aumenta o intervalo de teste e reduz a informação disponível para treinamento elevando as chances de erro nos testes.

A medida de desempenho  $\bar{P}$  é uma variável aleatória e para um número razoavelmente grande de experimentos pode ser aproximada para uma normal e ter seu desvio padrão,  $s$ , estimado como como ilustrado na Equação (4.2):

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{P}_i - \bar{\bar{P}})^2} \quad (4.2)$$

onde  $n$  corresponde ao número de experimentos e  $\bar{\bar{P}} = \frac{1}{n} \sum_{i=1}^n \bar{P}_i$ .

Alguns procedimentos realizados nesse trabalho são de verificação, e nesses adotou-se como critério de desempenho sua taxa de erro, isso se deve ao fato da medida de desempenho  $\bar{P}$  não ser eficaz quando o conjunto de testes apresenta um desequilíbrio muito grande na quantidade de padrões por classe, por exemplo, um classificador projetado para verificar se um padrão é positivo (pertencente a classe) ou impostor pode apresentar um desempenho,  $\bar{P}$ , muito elevado se a maioria dos padrões usados no teste também for positiva. Um falso positivo é um resultado errôneo onde um padrão impostor (negativo) é classificado como sendo legítimo (positivo) e para fins de medida de desempenho, dois valores serão considerados, o primeiro é a taxa de falsos positivos e o segundo é a taxa de falsos negativos expressos na Equação (4.3) e Equação (4.4) respectivamente.

$$R_{FP} = \frac{FP}{NN} \quad (4.3)$$

$$R_{FN} = \frac{FN}{NP} \quad (4.4)$$

onde:  $FP$  é o número de falsos positivos,  $FN$  é o de falsos negativos,  $NN$  é o número total de classes negativas de fato e  $NP$  é o número de classes positivas de fato. Quanto mais próximo de zeros essas taxas forem, melhor será o classificador.

Vale ressaltar o fato dessas medidas serem complementares, pois um classificador pode apresentar uma taxa excelente de falsos negativos (próximo de zero) e um péssimo desempenho no que se refere a taxa de falsos positivos.

# Capítulo 5

## Resultados do Sistema de Reconhecimento de Íris

Neste capítulo, iremos apresentar os resultados obtidos para o sistema de reconhecimento de íris proposto. Conforme mencionado no capítulo anterior, este sistema é projetado com filtros de correlação utilizando análise de componentes principais. O capítulo está organizado como segue: primeiramente, apresentamos os parâmetros investigados que influenciam diretamente no desempenho do sistema. A seguir, apresentamos os resultados obtidos para o sistema de reconhecimento de íris quando projetado com e sem o uso das componentes principais tanto para o filtro SDF quanto para o filtro MACE. Por fim, apresentamos as considerações finais.

### 5.1 Introdução

O sistema de reconhecimento de íris proposto neste trabalho foi explorado utilizando-se alguns parâmetros que influenciam diretamente no desempenho do sistema. A intenção é investigar o quanto estes parâmetros influenciam no desempenho do sistema. Especificamente, foram explorados os seguintes parâmetros:

- Base de dados: consiste no conjunto de imagens utilizadas para treino e teste. utilizou-se a seguinte base de dados: CASIA-Iris-Interval.
- Resolução segmentada: é a resolução da imagem segmentada e normalizada em domínio polar é expressa na forma *largura*  $\times$  *altura*;
- Imagens por classe: é o número mínimo de imagens que uma classes deve ter para ser pré-selecionada e compor o conjunto do teste. Classes da base de dados com quantidade menor ao especificado são ignoradas.

Após essa pré-seleção escolhemos um conjunto de classes que serão utilizadas para teste. Um teste é composto por avaliações para cada um dos valores do parâmetro considerado e cada avaliação é realizada através de um conjunto de experimentos. Cada experimento é realizado com o mesmo conjunto de classes, variando apenas nas imagens de teste e treino selecionadas. Como exemplo, se for de interesse conhecer o desempenho de um classificador SDF com PCA em função do número,  $n$ , de componentes principais selecionadas, para cada valor de  $n$  serão realizados vários experimentos e a média de desempenho e o devido desvio padrão serão calculados. Além dos parâmetros citados, na maioria dos testes, apenas uma parte da imagem total da íris é usada, essa região selecionada segue o padrão de coordenadas ilustrada na Figura 5.1.




Figura 5.1: Sistema de coordenadas adotado, imagem com resolução de  $360 \times 100$ .

## 5.2 Resultados Obtidos com Filtro SDF

Nesta seção, abordados os resultados de desempenho do filtro SDF-PCA em relação ao classificador SDF sem análise de componentes principais. O processo consiste em escolher um grupo de classes e selecionar, aleatoriamente, um grupo de imagens para teste e outro de treino para cada uma das classes selecionada.

Em cada teste é realizada a comparação do sistema com e sem a análise de componentes principais, o sistema sem PCA é usado como sistema de controle e é ilustrado em azul nos gráficos de desempenho. A medida de correlação,  $C_i$ , entre um filtro  $H_n$  e uma imagem de teste ( $x_i$ ) é realizada através do produto interno entre a imagem, em forma vetorial (em domínio magnitude da DFT, normalizada para uma média  $\mu = 0$  e um desvio padrão  $\sigma = 1$ )  $X_i$  e o filtro.

Na avaliação de desempenho, a classe a qual pertence cada padrão é conhecida previamente, portanto, uma classificação é considerada correta quando o resultado obtido pelo classificador para um dado padrão é igual a classe à qual esse padrão de fato pertence. Cada teste consiste em uma determinada quantidade  $n$  de experimentos, e cada experimento possui uma taxa de acerto  $P_i$  igual a razão total de acertos pela quantidade máxima possível,  $T_i$ . O desempenho estimado é calculado através da média das taxas de acerto e sendo uma variável aleatória, pode ter seu desvio padrão amostral estimado como sendo o desvio padrão do conjunto formado pelas taxas de acerto.

### 5.2.1 Desempenho em Função do Número de Componentes Principais

Esse experimento visa verificar como a quantidade de componentes principais usadas para treinamento do filtro SDF pode influenciar em seu desempenho. Os parâmetros são listados na Tabela 5.1 e os resultados são mostrados na Tabela 5.2 e ilustrados na Figura 5.2.

Parâmetros	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	360×100
Imagens por classe	10
Imagens selecionadas por classe	10
Imagens de treino por classe	5
Imagens de teste por classe	4
Número de experimentos	20
Classes por experimento	50
Componentes Principais	1-5
Região selecionada ( $l_i, c_i, l_f, c_f$ )	(50, 1, 100, 90)

Tabela 5.1: Relação de parâmetros para o experimento de desempenho em função do número de componentes principais.

Componentes	Com PCA		Sem PCA	
	Desempenho	$\sigma$	Desempenho	$\sigma$
1	0,9357	0,0230	0,9393	0,0214
2	0,9370	0,0116	0,9323	0,0125
3	0,9323	0,0180	0,9320	0,0189
4	0,9217	0,0245	0,9240	0,0216
5	0,9290	0,0199	0,9260	0,0197

Tabela 5.2: Resultados para o experimento (teste) de desempenho em função do número de componentes principais.

Podemos verificar que o sistema projetado por filtros de correlação com análise de componentes principais tem desempenho levemente superior ao sistema projetado sem componentes principais.






Figura 5.2: Gráfico dos resultados para o experimento (teste) de desempenho em função do número de componentes principais. Em vermelho SDF-PCA, em azul SDF.

### 5.2.2 Desempenho em Função da Largura da Região Selecionada

O objetivo desse experimento é verificar de que forma a resolução da imagem de íris pode afetar o desempenho de um classificador SDF. Os parâmetros são listados na Tabela 5.3 e os resultados são mostrados na Tabela 5.4 e ilustrados na Figura 5.3.

Nesse experimento foi observado um desempenho superior da configuração SDF-PCA quando a região selecionada das imagens de prova era menor. Nas condições apresentadas, este modelo apresentou desempenho significativamente superior quando a largura da região selecionada foi inferior a 50 pontos (Figura 5.3) denotando uma tendência de melhora em situações nas quais há baixa quantidade de informação nas imagens de prova.

Parâmetros	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	$360 \times 100$
Imagens por classe	10
Imagens selecionadas por classe	10
Imagens de treino por classe	5
Imagens de teste por classe	4
Número de experimentos	20
Classes por experimento	50
Componentes Principais	2
Região selecionada ( $l_i, c_i, l_f, c_f$ )	(50, 1, 100, 10-360)

Tabela 5.3: Relação de parâmetros para o experimento de variação da largura da região selecionada.




Figura 5.3: Gráficos dos resultados para o experimento (teste) de desempenho em função da largura da região selecionada. Em vermelho SDF-PCA, em azul SDF.

Largura	Com PCA		Sem PCA	
	Desempenho	$\sigma$	Desempenho	$\sigma$
10	NaN	NaN	NaN	NaN
20	0,6620	0,0339	0,4858	0,0409
30	0,8848	0,0250	0,8172	0,0325
40	0,9475	0,0158	0,9312	0,0197
50	0,9592	0,0153	0,9547	0,0201
60	0,9700	0,0161	0,9690	0,0178
70	0,9597	0,0182	0,9520	0,0205
80	0,9532	0,0162	0,9520	0,0223
90	0,9340	0,0178	0,9342	0,0156
100	0,9335	0,0169	0,9320	0,0232
110	0,9230	0,0248	0,9230	0,0244
120	0,9153	0,0240	0,9183	0,0226
130	0,9120	0,0211	0,9200	0,0204
140	0,9227	0,0250	0,9198	0,0263
150	0,9355	0,0264	0,9287	0,0288
160	0,9320	0,0153	0,9345	0,0149
170	0,9388	0,0136	0,9393	0,0133
180	0,9507	0,0169	0,9515	0,0173
190	0,9527	0,0199	0,9502	0,0167
200	0,9565	0,0151	0,9575	0,0169
210	0,9612	0,0128	0,9633	0,0099
220	0,9597	0,0111	0,9615	0,0126
230	0,9622	0,0165	0,9630	0,0148
240	0,9717	0,0105	0,9715	0,0096
250	0,9722	0,0144	0,9715	0,0132
260	0,9752	0,0066	0,9770	0,0075
270	0,9703	0,0174	0,9755	0,0136
280	0,9788	0,0131	0,9815	0,0119
290	0,9730	0,0116	0,9760	0,0102
300	0,9760	0,0088	0,9790	0,0075
310	0,9720	0,0116	0,9738	0,0112
320	0,9745	0,0131	0,9755	0,0123
330	0,9838	0,0079	0,9830	0,0089
340	0,9797	0,0102	0,9823	0,0104
350	0,9778	0,0098	0,9770	0,0101
360	0,9813	0,0087	0,9820	0,0095

Tabela 5.4: Resultados para o experimento (teste) de variação da largura da região selecionada.

### 5.2.3 Desempenho em Função da Altura da Região Selecionada

Sabe-se que algumas regiões da íris estão sujeitas a distorções diferenciadas, por exemplo, a região próxima a pupila é mais esticada no processo de conversão das

coordenadas do domínio retangular para polar, da mesma forma, a região mais afastada da pupila é sujeita a oclusão pela pálpebra.

O objetivo desse experimento é avaliar de que forma a distância tomada em relação a borda da íris (região com maior informação, entretanto, sujeita a oclusão) para segmentação pode afetar o desempenho de um classificador SDF. Os parâmetros são listados na Tabela 5.5 e os resultados são mostrados na Tabela 5.6 e ilustrados na Figura 5.4. A resolução original de segmentação não é alterada entretanto um fragmento de largura  $c$  é extraído da imagem segmentada e usado no processo de treino e teste.

Parâmetros	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	$360 \times 100$
Imagens por classe	10
Imagens selecionadas por classe	10
Imagens de treino por classe	5
Imagens de teste por classe	4
Número de experimentos	20
Classes por experimento	50
Componentes Principais	2
Região selecionada ( $l_i, c_i, l_f, c_f$ )	(1, 1, 10-100, 360)

Tabela 5.5: Relação de parâmetros para o experimento de variação da largura da região selecionada.

altura	Com PCA		Sem PCA	
	Desempenho	$\sigma$	Desempenho	$\sigma$
10	0,2998	0,0399	0,2753	0,0245
20	0,4510	0,0411	0,4475	0,0434
30	0,5767	0,0387	0,5847	0,0354
40	0,6935	0,0486	0,7193	0,0419
50	0,7880	0,0337	0,8122	0,0323
60	0,8505	0,0295	0,8760	0,0247
70	0,9067	0,0248	0,9190	0,0207
80	0,9312	0,0230	0,9460	0,0229
90	0,9568	0,0163	0,9647	0,0156
100	0,9602	0,0150	0,9712	0,0153

Tabela 5.6: Resultados para o experimento (teste) de desempenho em função da altura da área selecionada.

Como resultado se percebe a menores ganhos entre o modelo SDF-PCA e SDF, apesar de parecer contraditório com os resultados obtidos na Seção 5.2.2 tal resultado




Figura 5.4: Gráficos dos resultados para o experimento (teste) de desempenho em função da altura da região selecionada. Em vermelho SDF-PCA, em azul SDF.

pode ser explicado devido ao fato da área ser tomada a partir da região mais próxima das pálpebras havendo portando oclusão por parte da íris dificultando o processo de classificação. Esse experimento é repetido na Seção 5.2.5 variando a distância a partir da pupila e portando evitando oclusão da pálpebra quando a área selecionada for pequena obtendo resultados bem diferentes mostrados na Figura 5.6.

#### 5.2.4 Desempenho em Função da Relação Sinal/Ruído

Neste experimento acrescentamos ruído gaussiano às imagens utilizadas. Nosso objetivo é determinar o quando um ruído pode afetar o desempenho dos classificadores. A relação sinal/ruído usada consiste na razão entre a variância do ruído adicionado e a originalmente presente na imagem. Os parâmetros são listados na Tabela 5.7 e os resultados são mostrados na Tabela 5.8 e ilustrados na Figura 5.5.

Nas condições apresentadas não foi possível perceber diferença significativa entre os modelos SDF e SDF-PCA, ambos apresentaram resultados similares.

Parâmetros	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	360×100
Imagens por classe	10
Imagens selecionadas por classe	10
Imagens de treino por classe	5
Imagens de teste por classe	4
Número de experimentos	20
Classes por experimento	50
Componentes Principais	2
Região selecionada ( $l_i, c_i, l_f, c_f$ )	(50, 1, 100, 90)

Tabela 5.7: Relação de parâmetros para variação da relação sinal/ruído




Figura 5.5: Gráficos dos resultados para o experimento (teste) de desempenho em função da relação sinal/ruído. Em vermelho SDF-PCA, em azul SDF.

### 5.2.5 Desempenho em Função da Relação Raio de Segmentação

Esse experimento é similar ao 5.2.3 diferenciando-se no fato de que a distância é tomada em relação a borda da pupila. Assim, espera-se avaliar o desempenho dos classificadores a partir de uma região com baixa resolução próxima a pupila até uma região com densidade de informação mais elevada presente nas áreas próximas à fronteira da íris. Os parâmetros são listados na Tabela 5.9 e os resultados são mostrados na Tabela 5.10 e ilustrados na Figura 5.6.

Assim como no experimento realizado na Seção 5.2.2 notamos um desempenho superior do SDF-PCA em relação ao SDF clássico em situações nas quais a quantidade




Figura 5.6: Gráfico dos resultados para o experimento (teste) de desempenho em função do raio de segmentação. Em vermelho SDF-PCA, em azul SDF.

de informação dos parões de prova é significativamente reduzida. Esse experimento também é similar ao realizado na Seção 5.2.3 diferindo no fato de tomar a região a partir da pupila e não do limiar externo da íris e obtendo resultados melhores para o modelo SDF-PCA em relação ao SDF nessas condições.

### 5.2.6 Desempenho em Função do Número de Imagens de Treino

Esse experimento traz como meta determinar se de alguma forma o número de imagens utilizadas para treino afetaria o resultado obtido pelo classificador. Os parâmetros são listados na Tabela 5.11 e os resultados são mostrados na Tabela 5.12 e ilustrados na Figura 5.7.

Neste experimento não foi possível perceber diferenças significativas entre os modelos, ambos apresentaram resultados similares nas condições especificadas conforme mostrado na Figura 5.7. É curioso notar o fato de o número de imagens usadas no treino não afetar de forma significativa o desempenho dos filtros denotando o fato de que




Figura 5.7: Gráfico dos resultados para o experimento (teste) de desempenho em função do número de imagens de treino. Em vermelho SDF-PCA, em azul SDF.

uma única imagem de íris, na resolução usada nesse trabalho, apresentar por si só um alto índice de singularidade e informação biométrica, resultando em boa classificação.



SNR	Com PCA		Sem PCA	
	Desempenho	$\sigma$	Desempenho	$\sigma$
1,000000e-02	0,1565	0,0295	0,1613	0,0306
1,258925e-02	0,1663	0,0253	0,1692	0,0293
1,584893e-02	0,1712	0,0274	0,1620	0,0238
1,995262e-02	0,1682	0,0241	0,1742	0,0197
2,511886e-02	0,1777	0,0258	0,1663	0,0241
3,162278e-02	0,1845	0,0124	0,1655	0,0197
3,981072e-02	0,1852	0,0238	0,1752	0,0281
5,011872e-02	0,1798	0,0261	0,1738	0,0303
6,309573e-02	0,1940	0,0297	0,1880	0,0180
7,943282e-02	0,1898	0,0229	0,1833	0,0267
1,000000e-01	0,1918	0,0225	0,1920	0,0227
1,258925e-01	0,1993	0,0302	0,1925	0,0326
1,584893e-01	0,2320	0,0263	0,2178	0,0304
1,995262e-01	0,2450	0,0325	0,2340	0,0260
2,511886e-01	0,2767	0,0329	0,2578	0,0371
3,162278e-01	0,3078	0,0280	0,2970	0,0438
3,981072e-01	0,3583	0,0395	0,3357	0,0303
5,011872e-01	0,4348	0,0294	0,3878	0,0329
6,309573e-01	0,4815	0,0311	0,4425	0,0265
7,943282e-01	0,5665	0,0317	0,5440	0,0368
1	0,6537	0,0447	0,6103	0,0467
1,258925e+00	0,7130	0,0275	0,6762	0,0348
1,584893e+00	0,7660	0,0329	0,7388	0,0400
1,995262e+00	0,8010	0,0283	0,7835	0,0193
2,511886e+00	0,8443	0,0364	0,8212	0,0455
3,162278e+00	0,8790	0,0255	0,8595	0,0340
3,981072e+00	0,8950	0,0224	0,8775	0,0234
5,011872e+00	0,9077	0,0204	0,9018	0,0238
6,309573e+00	0,9078	0,0271	0,9042	0,0226
7,943282e+00	0,9247	0,0230	0,9275	0,0202
10	0,9268	0,0144	0,9325	0,0206
1,258925e+01	0,9215	0,0206	0,9248	0,0200
1,584893e+01	0,9318	0,0148	0,9400	0,0145
1,995262e+01	0,9335	0,0173	0,9338	0,0163
2,511886e+01	0,9300	0,0284	0,9320	0,0285
3,162278e+01	0,9355	0,0210	0,9385	0,0216
3,981072e+01	0,9393	0,0180	0,9382	0,0200
5,011872e+01	0,9303	0,0189	0,9382	0,0161
6,309573e+01	0,9365	0,0172	0,9362	0,0161
7,943282e+01	0,9272	0,0191	0,9280	0,0185
100	0,9327	0,0182	0,9300	0,0180

Tabela 5.8: Resultados para o experimento (teste) de desempenho em função da relação sinal/ruído.

Parâmetros	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	360×100
Imagens por classe	10
Imagens selecionadas por classe	10
Imagens de treino por classe	5
Imagens de teste por classe	4
Número de experimentos	20
Classes por experimento	50
Componentes Principais	2
Região selecionada ( $l_i, c_i, l_f, c_f$ )	(0-90, 270, 100, 360)

Tabela 5.9: Parâmetros para o experimento variação do raio de segmentação.

Raio	Com PCA		Sem PCA	
	Desempenho	$\sigma$	Desempenho	$\sigma$
90	0,9630	0,0119	0,9663	0,0135
85	0,9642	0,0128	0,9655	0,0152
80	0,9672	0,0152	0,9683	0,0151
75	0,9673	0,0149	0,9663	0,0149
70	0,9740	0,0132	0,9760	0,0120
65	0,9758	0,0133	0,9788	0,0109
60	0,9713	0,0111	0,9735	0,0124
55	0,9768	0,0103	0,9782	0,0099
50	0,9780	0,0085	0,9795	0,0072
45	0,9738	0,0115	0,9770	0,0111
40	0,9718	0,0100	0,9737	0,0089
35	0,9730	0,0134	0,9713	0,0131
30	0,9683	0,0138	0,9682	0,0138
25	0,9643	0,0143	0,9635	0,0124
20	0,9385	0,0176	0,9225	0,0203
15	0,8660	0,0305	0,7937	0,0308
10	0,5830	0,0416	0,4128	0,0342
5	NaN	NaN	NaN	NaN
0	NaN	NaN	NaN	NaN

Tabela 5.10: Resultados para o experimento (teste) desempenho em função do raio de segmentação.

Parâmetros de teste	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	360×100
Imagens por classe	10
Imagens selecionadas por classe	10
Imagens de treino por classe	2-6
Imagens de teste por classe	4
Número de experimentos	20
Classes por experimento	50
Componentes Principais	2
Região selecionada ( $l_i, c_i, l_f, c_f$ )	(50, 270, 100, 360)

Tabela 5.11: Parâmetros para o experimento variação do número de imagens de treino.

Imagens de treino	Com PCA		Sem PCA	
	Desempenho	$\sigma$	Desempenho	$\sigma$
2	0,9572	0,0126	0,9575	0,0150
3	0,9695	0,0086	0,9705	0,0107
4	0,9730	0,0101	0,9768	0,0095
5	0,9735	0,0097	0,9743	0,0082
6	0,9775	0,0077	0,9782	0,0102

Tabela 5.12: Resultados para o experimento (teste) desempenho em função do número de imagens de treino.

### 5.3 Resultados obtidos com Filtro MACE e Filtros MACE-PCA

Nesta seção são ilustrados os resultados obtidos nos experimentos realizados com a utilização dos filtros MACE tradicional e os filtro MACE-PCA, o qual, nada mais é que um filtro MACE treinado para reconhecer a componente com maior variância presente no conjunto de imagens.

A métrica usada consiste em medir a similaridade entre o padrão de candidato e um modelo esperado de pico de energia conforme mencionado no Capítulo 3. Todas as imagens utilizadas são normalizadas em relação a média,  $\mu = 0$ , e desvio padrão,  $\sigma = 1$ .

Os experimentos consistem inicialmente em uma análise dos picos de energia obtidos em classificações positivas (quando o padrão pertence a classe dos padrões utilizados no treino do filtro) para então realizar as análises de desempenho e comparações entre os filtros.

#### 5.3.1 Comportamento dos Picos de Energia e Determinação de um Modelo para Validar Picos de Energia obtidos no Processo de Classificação

Os experimentos têm como objetivo estabelecer um modelo para a detecção de picos de correlação a ser utilizados nos testes posteriores. Os valores ponto a ponto do modelo foram determinados através do cálculo da média de todos os resultados para os quais a classificação deveria ser positiva (pico de energia esperado). A Tabela 5.13 ilustra os parâmetros de simulação e a Figura 5.8 a média obtida. Na Figura 5.9, temos o desvio padrão ponto a ponto. Os resultados obtidos são usados para determinação da existência de picos de correlação nos experimentos realizados com filtros MACE nas subseções.

#### 5.3.2 Comportamento dos Picos de Energia e Determinação de um Modelo para Validar Picos de Energia obtidos no Processo de Classificação MACE-PCA

Nesta subseção se estabelece um modelo que será utilizado na detecção de picos de energia no plano de correlação gerados por uma imagem candidata em um filtro MACE-PCA treinado para a primeira componente principal nas situações em que a classificação deveria ser positiva. A Tabela 5.13 ilustra os parâmetros de simulação a

Parâmetros	
Parâmetro	Valor
Base de dados	CASIA-Iris-Interval
Resolução segmentada	$360 \times 100$
Imagens selecionadas por classe	7
Imagens de treino por classe	6
Imagens de teste por classe	1
Número de experimentos	50
Classes por experimento	50
Componentes Principais	1
Região selecionada $(l_i, c_i, l_f, c_f)$	(50, 1, 100, 90)

Tabela 5.13: Parâmetros do experimento para detecção de picos de correlação.

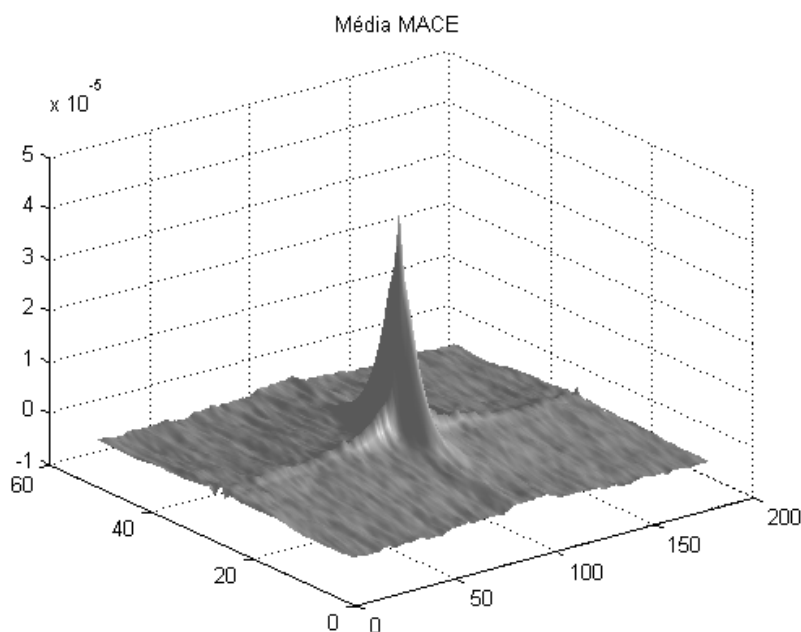


Figura 5.8: Média de picos de energia obtidos quando a imagem pertence ao conjunto de treinamento utilizadas no projeto do filtro de correlação.

Figura 5.10 a média obtida e a Figura 5.11 o desvio padrão ponto a ponto. Os resultados aqui obtidos são usados para determinação da existência de picos de correlação nos experimentos realizados com filtros MACE nas subseções.

### 5.3.3 Coeficiente de Sobreposição entre o Coeficiente de Correlação entre a Saída e o Modelo de Pico de Energia

Esse experimento visa verificar quantitativamente a qualidade do coeficiente de correlação obtido entre a saída e modelo de pico de energia visando avaliar o efeito




Figura 5.9: Desvio padrão de cada ponto da Figura 5.8.




Figura 5.10: Média de picos de energia obtidos quando a imagem pertence ao conjunto de treinamento utilizadas no projeto do filtro de correlação.

que a adoção do uso da PCA no processo de treinamento do filtro têm sobre o mesmo. Tal coeficiente é abordado na Seção 3.2.2. Como modelos de referência foram usados o modelo obtido nas Seções 5.3.1 e 5.3.2 para determinação dos coeficientes de correlação




Figura 5.11: Desvio padrão de cada ponto da Figura 5.8.

para os classificadores MACE e PCA. Os parâmetros utilizados são ilustrados na Tabela 5.13;

Nesse experimento foram criados dois conjuntos de dados. O primeiro é constituído por todos os coeficientes de correlação para os quais o filtro deveria reagir positivamente (pico de energia no plano de correlação). O segundo é formado pelos coeficientes de correlação para os quais se espera reação negativa do filtro (sem pico de energia definido), de posse desses dados são construídas duas curvas representando a distribuição estatística de cada um dos conjuntos em seguida são avaliados os pontos de intersecção, os coeficientes de sobreposição, média e desvio padrão para cada um dos conjuntos. De posse desse conjunto de valores é possível avaliar o limiar de classificação e a qualidade do parâmetro usado para classificação (através do coeficiente OVL).

Os resultados obtidos para o MACE-PCA são ilustrados na Figura 5.12. Os resultados para o filtro MACE são ilustrados na Figura 5.13 e por fim, um comparativo dos resultados obtidos são mostrados na Tabela 5.14.

Os resultados foram bem similares em ambas as situações apresentando o filtro MACE-PCA um desempenho médio levemente inferior tendo, entretanto, um nível de superposição entre as zonas de rejeição e aprovação (OVC) melhor em relação ao apresentado pelo modelo MACE clássico, vide Tabela 5.14.




Figura 5.12: Distribuição estatística dos valores de correlação com o modelo para um filtro MACE-PCA. Em vermelho, zona de rejeição e em azul zona de aprovação.




Figura 5.13: Distribuição estatísticas dos valores de correlação com o modelo para um filtro MACE clássico (em vermelho zona de rejeição e em azul zona de aprovação).



Filtro	Rejeição		Aprovação		Métricas de classificação	
	$\mu$	$\sigma$	$\mu$	$\sigma$	OVC	Limiar de classificação
MACE	0,0291	0,1161	0,3602	0,1337	0,1845	0,1896
MACE-PCA	0,0351	0,1206	0,3743	0,1301	0,1757	0,2017

Tabela 5.14: Análise estatística do coeficiente de correlação da saída do filtro com o modelo de pico de energia. O limiar de classificação é o melhor ponto para separar classes negativas de positivas.

### 5.3.4 Resultado para os Teste de Verificação

Um teste de verificação tem como objetivo identificar um possível padrão impostor, ou seja, é afirmado previamente que determinado padrão pertence, ou não, a uma dada classe e o classificador avalia a veracidade dessa afirmação. Dois parâmetros são avaliados: falsos positivos e falsos negativos. Toda vez que um classificador infere que um determinado padrão pertence a uma classe à qual ele não faz parte, temos um falso positivo e quando um classificador infere que um padrão não pertence a classe à qual de fato faz parte, temos um falso negativo.

Dado um conjunto de  $N$  padrões de teste pertencentes a uma classe  $C$  e considerando-se um classificador projetado para verificar padrões dessa classe, denomina-se taxa de falsos negativos a razão entre a quantidade de classes rejeitadas e o número de padrões que deveriam ser aceitos,  $N$ . Da mesma forma, a taxa de falsos positivos, é a relação entre a quantidade de positivos obtidos em um conjunto de rejeição sobre a quantidade total de elementos desse conjunto.

Para esse teste foram realizados cinquenta experimentos, em cada experimento 50 classes foram escolhidas aleatoriamente. Para cada classe um filtro MACE e um MACE-PCA foram treinados e foi selecionada uma imagem de teste para cada classe a qual não fazia parte do conjunto de treinamento. O teste consiste em avaliar quantos erros são obtidos (falsos positivos e falsos negativos) e gerar as respectivas taxas. Resultados desse experimento são ilustrados na Tabela 5.15.

Filtro	Taxas de teste de verificação			
	Falsos-positivos		Falsos-negativos	
	$\mu$	$\sigma$	$\mu$	$\sigma$
MACE	0,0793	0,0075	0,1068	0,0332
MACE-PCA	0,0804	0,0092	0,1072	0,0320

Tabela 5.15: Comparativo entre taxas de falsos positivos e falsos negativos,  $\mu$  representa a média e  $\sigma$  é o desvio padrão.

### 5.3.5 Resultado de Teste de Verificação em Função da Quantidade de Imagens de Treino

Esse teste objetiva mostrar como a variação na quantidade de padrões de treino por classe pode afetar as métricas de desempenho aqui abordadas. Os parâmetros desse teste são em essência os mesmos utilizados na seção 5.3.4 com exceção do número de experimentos, reduzidos a dez por valor avaliado do parâmetro variante, em fato, aqui é replicado o teste da Seção 5.3.4, para cada valor escolhido do parâmetro variante (no caso a quantidade de imagens de treino).

Os resultados são ilustrados nas Tabelas 5.16 e 5.17 e ilustrados nas Figuras 5.14 até 5.17.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
2	0,1620	0,0649	0,1274	0,0076	0,1869	0,2998
3	0,1860	0,0389	0,1264	0,0068	0,1821	0,3135
4	0,1040	0,0337	0,0840	0,0056	0,1976	0,1920
5	0,1280	0,0492	0,0897	0,0045	0,1816	0,2215
6	0,0980	0,0333	0,0762	0,0065	0,1969	0,1782

Tabela 5.16: Resultados obtidos variando-se o número de imagens de treino para o filtro MACE.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
2	0,1680	0,0454	0,1313	0,0085	0,1875	0,3305
3	0,2020	0,0257	0,1287	0,0081	0,1862	0,3463
4	0,1180	0,0346	0,0985	0,0101	0,1986	0,2353
5	0,1320	0,0379	0,1005	0,0061	0,1822	0,3033
6	0,1200	0,0267	0,0782	0,0062	0,2013	0,1839

Tabela 5.17: Resultados obtidos variando-se o número de imagens de treino para o filtro MACE-PCA.

Neste experimento observamos equivalência entre o MACE e o MACE-PCA. Com uma vantagem na média para o filtro MACE padrão nestas condições (vide Tabelas 5.16 e 5.17) o coeficiente de sobreposição foi também superior no modelo clássico sem que houvesse diferenciação expressiva sendo que ambos os resultados ficaram praticamente sobrepostos quando considerados os devidos desvios padrões nas medidas.




Figura 5.14: Taxa de falsos positivos em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul.




Figura 5.15: Taxa de falsos negativos em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul.

### 5.3.6 Resultado de Teste de Variação da Largura

Esse teste visa determinar como a quantidade de informação presente em cada imagem de treino afeta o desempenho do sistema, medido em termos de falsos positivos e falsos negativos e os parâmetros dos testes são os mesmos ilustrados na Tabela 5.13 diferindo na largura da região segmentada, ou seja, para o teste abaixo,  $c_f$ , é verificado para valores no intervalo  $[10, 360]$  o pico de energia na saída do filtro de correlação é medido através de sua correlação cruzada com o modelo ilustrado na Figura 5.10 a qual é re-escalada de modo a ter a mesma dimensão do resultado do filtro de correlação. Os resultados obtidos são mostrados nas Tabelas 5.18 e 5.19 sendo ilustrados na Figuras 5.18 até 5.21.




Figura 5.16: Limiar de classificação em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul.




Figura 5.17: OVC em função do número de imagens de treino. MACE-PCA em vermelho, MACE em azul.

Similarmente ao que já foi demonstrado para os modelos SDF mostrados na Seção 5.2.2 novamente percebe-se como o uso da PCA nas imagens de prova melhora o desempenho de um classificador em situações nas quais a quantidade de informação presente é escassa, nota-se uma sensível melhora no índice de falsos-positivos (Figura 5.18) e alguma melhora na taxa de falsos-negativos mostrada na Figura 5.19 resultados corroborados pelos melhores valores de OVC obtidos pelo MACE-PCA e mostrados na Figura 5.21.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
10	0,3630	0,0491	0,1795	0,0080	0,0768	0,5163
20	0,2880	0,0470	0,1502	0,0076	0,1086	0,4119
30	0,1710	0,0428	0,1196	0,0082	0,1214	0,2865
40	0,1780	0,0355	0,1168	0,0070	0,1359	0,2733
50	0,1530	0,0391	0,1168	0,0066	0,1413	0,2564
60	0,1890	0,0479	0,1133	0,0053	0,1459	0,2893
70	0,1710	0,0328	0,0938	0,0085	0,1457	0,2613
80	0,1410	0,0452	0,0975	0,0070	0,1533	0,2261
90	0,1880	0,0451	0,1206	0,0050	0,1438	0,2836
100	0,1770	0,0380	0,1086	0,0071	0,1484	0,2761
110	0,1640	0,0452	0,1299	0,0074	0,1491	0,2819
120	0,1560	0,0408	0,1104	0,0072	0,1542	0,2503
130	0,1550	0,0420	0,1002	0,0062	0,1667	0,2275
140	0,1630	0,0422	0,1129	0,0098	0,1621	0,2470
150	0,1290	0,0418	0,0889	0,0084	0,1700	0,2174
160	0,1480	0,0442	0,0985	0,0071	0,1724	0,2350
170	0,1240	0,0403	0,0841	0,0068	0,1793	0,2029
180	0,0820	0,0361	0,0758	0,0050	0,1915	0,1585
190	0,0980	0,0304	0,0852	0,0069	0,1894	0,1813
200	0,0990	0,0301	0,0850	0,0063	0,1937	0,1733
210	0,1040	0,0302	0,0826	0,0063	0,2006	0,1814
220	0,0820	0,0361	0,0779	0,0069	0,2070	0,1530
230	0,0910	0,0402	0,0811	0,0082	0,2041	0,1731
240	0,0830	0,0417	0,0652	0,0066	0,2159	NaN
250	0,0830	0,0299	0,0835	0,0073	0,2047	0,1562
260	0,0870	0,0369	0,0898	0,0057	0,1962	NaN
270	0,0980	0,0440	0,0876	0,0089	0,1784	0,2013
280	0,1010	0,0314	0,0811	0,0056	0,1969	NaN
290	0,0960	0,0256	0,0710	0,0074	0,1973	0,1544
300	0,0630	0,0270	0,0762	0,0075	0,2100	NaN
310	0,0770	0,0299	0,0753	0,0057	0,1957	0,1618
320	0,0760	0,0382	0,0741	0,0066	0,1930	NaN
330	0,0670	0,0320	0,0641	0,0060	0,2062	NaN
340	0,0870	0,0313	0,0829	0,0070	0,2052	0,1713
350	0,0780	0,0224	0,0669	0,0052	0,2132	NaN
360	0,0840	0,0302	0,0761	0,0056	0,2102	NaN

Tabela 5.18: Resultados obtidos variando-se a largura da região segmentada para o filtro MACE.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
10	0,3070	0,0540	0,1586	0,0092	0,1137	0,4367
20	0,2700	0,0452	0,1419	0,0073	0,1234	0,3974
30	0,1790	0,0461	0,1119	0,0091	0,1307	0,2881
40	0,1960	0,0393	0,1083	0,0093	0,1417	0,2693
50	0,1510	0,0509	0,0936	0,0055	0,1449	0,2304
60	0,1690	0,0586	0,0970	0,0058	0,1479	0,2530
70	0,1710	0,0381	0,0927	0,0110	0,1468	0,2764
80	0,1450	0,0389	0,0873	0,0076	0,1559	0,2238
90	0,1580	0,0415	0,1082	0,0078	0,1526	0,2577
100	0,1720	0,0375	0,1043	0,0064	0,1516	0,2733
110	0,1540	0,0499	0,1194	0,0104	0,1513	0,2883
120	0,1630	0,0427	0,1018	0,0082	0,1597	0,2448
130	0,1430	0,0417	0,0975	0,0072	0,1695	0,2480
140	0,1650	0,0458	0,1125	0,0097	0,1680	0,2937
150	0,1370	0,0417	0,0988	0,0101	0,1776	0,2443
160	0,1320	0,0470	0,0907	0,0070	0,1809	0,2217
170	0,1430	0,0441	0,0862	0,0077	0,1828	0,2185
180	0,0970	0,0396	0,0808	0,0062	0,1997	NaN
190	0,1260	0,0319	0,0914	0,0084	0,1931	0,1979
200	0,1000	0,0426	0,0960	0,0084	0,2015	0,1907
210	0,1110	0,0397	0,0880	0,0073	0,1962	0,2092
220	0,0670	0,0285	0,0886	0,0075	0,2119	0,1743
230	0,0880	0,0451	0,0986	0,0131	0,2033	0,2120
240	0,0890	0,0413	0,0841	0,0078	0,2061	0,1774
250	0,0920	0,0358	0,0912	0,0068	0,2026	0,1799
260	0,0690	0,0381	0,0972	0,0074	0,1986	NaN
270	0,1070	0,0465	0,1100	0,0073	0,1785	0,2469
280	0,1110	0,0286	0,0899	0,0079	0,1874	NaN
290	0,1000	0,0331	0,0785	0,0072	0,1955	0,1704
300	0,0680	0,0321	0,0865	0,0077	0,2052	NaN
310	0,0920	0,0278	0,0867	0,0060	0,1912	0,1919
320	0,0820	0,0361	0,0918	0,0077	0,1879	0,1752
330	0,0760	0,0403	0,0719	0,0078	0,1990	0,1556
340	0,1050	0,0310	0,0901	0,0055	0,1982	0,1977
350	0,0700	0,0294	0,0783	0,0082	0,2061	NaN
360	0,0890	0,0352	0,0800	0,0067	0,2041	0,1622

Tabela 5.19: Resultados obtidos variando-se a largura da região segmentada para o filtro MACE-PCA.

### 5.3.7 Resultado de Teste de Variação de Fator de Escala

Esse teste visa determinar como a quantidade de informação presente em cada imagem de treino afeta o desempenho do sistema (em termos de falsos positivos e falsos




Figura 5.18: Taxa de falsos positivos em função da largura. MACE-PCA em vermelho, MACE em azul.




Figura 5.19: Taxa de falsos negativos em função da largura. MACE-PCA em vermelho, MACE em azul.

negativos). Os parâmetros dos testes são os mesmos ilustrados na Tabela 5.13. Nesse teste, um fator de escala é aplicado nas imagens afim de simular situações de captura distante, notar que quanto menor for o fator de escala, maior será a quantidade de informação perdida e mais difícil será o processo de classificação. O parâmetro medido nesse consiste no valor do coeficiente de correlação cruzada entre o resultado do filtro de correlação e o modelo devidamente re-escalonado para mesmas dimensões.




Figura 5.20: Limiar de classificação em função da largura. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'.  
'x' e filtro MACE-PCA '+'.




Figura 5.21: OVC em função da largura. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'.



Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
0,20	0,2430	0,0469	0,2075	0,0154	0,0644	0,4525
0,25	0,2670	0,0491	0,2014	0,0100	0,0845	0,4816
0,30	0,1640	0,0522	0,1177	0,0087	0,1220	0,2624
0,35	0,1480	0,0487	0,1119	0,0078	0,1266	0,2665
0,40	0,1350	0,0250	0,0748	0,0054	0,1503	0,1982
0,45	0,1380	0,0467	0,0980	0,0055	0,1475	0,2378
0,50	0,1160	0,0239	0,0792	0,0067	0,1568	0,1888
0,55	0,1040	0,0393	0,0859	0,0044	0,1627	0,1871
0,60	0,1140	0,0319	0,0711	0,0069	0,1741	0,1765
0,65	0,1270	0,0363	0,0844	0,0047	0,1617	0,2050
0,70	0,0940	0,0332	0,0683	0,0050	0,1846	0,1518
0,75	0,1160	0,0428	0,0842	0,0076	0,1638	0,2105
0,80	0,1330	0,0504	0,0817	0,0060	0,1762	0,2072
0,85	0,1030	0,0407	0,0844	0,0081	0,1790	0,1801
0,90	0,0680	0,0340	0,0592	0,0067	0,2063	0,1290
0,95	0,1020	0,0282	0,0667	0,0064	0,2022	NaN
1,00	0,0990	0,0413	0,0970	0,0076	0,1723	0,2130

Tabela 5.20: Resultados obtidos variando-se a escala da região segmentada para o filtro MACE.

### 5.3.8 Limiar de Classificação para Relação entre Pico e Desvio Padrão

Esse teste replica o anteriormente realizado na seção 5.3.3 diferenciando-se no fato de empregar a relação entre o valor de pico e o desvio padrão em contraste ao anterior que empregava uma métrica de similaridade com um modelo de saída esperada. Os resultados desse teste são mostrados na Tabela 5.22 e ilustrados na Figura 5.26 e Figura 5.27.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
0,20	0,1150	0,0449	0,0892	0,0062	0,1687	0,2147
0,25	0,2080	0,0492	0,1777	0,0082	0,1239	0,4244
0,30	0,1200	0,0527	0,1137	0,0103	0,1560	0,2720
0,35	0,1810	0,0475	0,1112	0,0081	0,1512	0,3103
0,40	0,1140	0,0395	0,0724	0,0068	0,1821	0,1751
0,45	0,1450	0,0410	0,1108	0,0108	0,1660	0,2881
0,50	0,1370	0,0374	0,0880	0,0074	0,1804	0,1998
0,55	0,1200	0,0405	0,0850	0,0060	0,1753	0,2015
0,60	0,0990	0,0375	0,0753	0,0057	0,1918	0,1745
0,65	0,1510	0,0381	0,0930	0,0061	0,1738	0,2284
0,70	0,0900	0,0418	0,0794	0,0068	0,1927	0,1761
0,75	0,1200	0,0584	0,1008	0,0072	0,1775	0,2174
0,80	0,1210	0,0413	0,0907	0,0073	0,1852	0,2334
0,85	0,1360	0,0408	0,0957	0,0085	0,1837	0,2089
0,90	0,0880	0,0327	0,0771	0,0068	0,1993	0,1572
0,95	0,0960	0,0211	0,0867	0,0081	0,2030	NaN
1,00	0,1360	0,0413	0,1069	0,0083	0,1754	0,2768

Tabela 5.21: Resultados obtidos variando-se a escala da região segmentada para o filtro MACE-PCA.

Filtro	Rejeição		Aprovação		Métricas de classificação	
	$\mu$	$\sigma$	$\mu$	$\sigma$	OVC	Limiar de classificação
MACE	3,8015	0,5774	10,5974	3,7125	0,0713	5,1965
MACE-PCA	4,1931	0,8150	12,2877	4,5051	0,0861	6,0733

Tabela 5.22: Análise estatística da relação pico/desvio padrão da saída do filtro de correlação, o limiar de classificação é expresso nessa relação.

A abordagem do uso da relação pico desvio padrão, mostrada na Tabela 5.22, ofereceu melhores resultados do que os obtidos através do índice de correlação entre a saída do correlador e um pico de energia modelo conforme Tabela 5.14. A vantagem do uso desta relação parâmetro como critério de classificação é notado através dos valores menores obtidos para OVC indicando menor interseção entre as zonas de rejeição e aprovação tanto para o MACE quanto para o MACE-PCA, por essa razão alguns experimentos serão repetidos nas seções utilizando-se essa nova medida e comparados com resultados obtidos anteriormente.




Figura 5.22: Taxa de falsos positivos em função da escala. MACE-PCA em vermelho, MACE em azul.




Figura 5.23: Taxa de falsos negativos em função da escala. MACE-PCA em vermelho, MACE em azul.




Figura 5.24: Limiar de classificação em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'.  
+




Figura 5.25: OVC em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'.  
+




Figura 5.26: Análise ilustração da Tabela 5.22 para filtro do tipo MACE-PCA. Zona de rejeição em vermelho e zona de aprovação em azul.




Figura 5.27: Análise ilustração da Tabela 5.22 para filtro do tipo MACE. Zona de rejeição em vermelho e zona de aprovação em azul.

### 5.3.9 Desempenho em Função da Largura medindo-se a Relação entre Pico e Desvio Padrão

Esse teste replica o realizado na seção 5.3.6 diferenciando-se no fato de usar como característica de classificação a relação pico / desvio padrão. Os parâmetros do teste são os mesmos utilizados na seção supracitada diferindo-se apenas na característica escolhida para classificação. Os resultados obtidos nesse teste são mostrados nas Tabelas 5.23 e 5.24 sendo ilustrados nas Figuras 5.28, 5.29, 5.30 e 5.31.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
10	0,0020	0,0062	0,9968	0,0015	2,2724	0,9489
20	0,3960	0,0513	0,0901	0,0063	3,7401	0,4156
30	0,1950	0,0366	0,0517	0,0070	4,0358	0,2166
40	0,1810	0,0392	0,0480	0,0082	4,1229	0,2006
50	0,1200	0,0343	0,0395	0,0053	4,3837	0,1310
60	0,1810	0,0386	0,0372	0,0062	4,3590	0,1464
70	0,1800	0,0421	0,0363	0,0042	4,4918	0,1510
80	0,1320	0,0314	0,0356	0,0038	4,4967	0,1386
90	0,0750	0,0233	0,0328	0,0046	4,6265	0,1042
100	0,1590	0,0352	0,0332	0,0046	4,6552	0,1302
110	0,1960	0,0382	0,0312	0,0063	4,7081	0,1446
120	0,1530	0,0320	0,0307	0,0041	4,7819	0,1224
130	0,1770	0,0391	0,0413	0,0067	4,9110	0,1495
140	0,1490	0,0294	0,0335	0,0046	4,9679	0,1094
150	0,1230	0,0417	0,0278	0,0028	4,9262	0,0992
160	0,1080	0,0293	0,0309	0,0044	5,0981	0,1095
170	0,1630	0,0446	0,0365	0,0052	5,0815	0,1312
180	0,0920	0,0293	0,0303	0,0043	5,3304	0,0787
190	0,0990	0,0263	0,0368	0,0051	5,4160	0,0989
200	0,0640	0,0295	0,0255	0,0027	5,4020	0,0572
210	0,0840	0,0211	0,0333	0,0048	5,3693	0,0836
220	0,0820	0,0324	0,0272	0,0039	5,3901	0,0723
230	0,0880	0,0263	0,0333	0,0032	5,4526	0,0927
240	0,0600	0,0337	0,0273	0,0040	5,5386	0,0721
250	0,0800	0,0297	0,0313	0,0043	5,7912	0,0738
260	0,0920	0,0407	0,0299	0,0050	5,8030	0,0812
270	0,0630	0,0285	0,0311	0,0033	6,0143	0,0740
280	0,0610	0,0294	0,0278	0,0044	5,8843	0,0633
290	0,0640	0,0280	0,0288	0,0046	5,8577	0,0756
300	0,0750	0,0389	0,0273	0,0053	5,9489	0,0602
310	0,0560	0,0280	0,0302	0,0038	5,9772	0,0691
320	0,0690	0,0321	0,0222	0,0029	6,0084	0,0535
330	0,0590	0,0177	0,0237	0,0035	6,0903	0,0533
340	0,0580	0,0204	0,0253	0,0048	6,2441	0,0498
350	0,0710	0,0220	0,0256	0,0030	6,0971	0,0757
360	0,0530	0,0218	0,0318	0,0049	6,4838	0,0647

Tabela 5.23: Resultados obtidos variando-se a largura da região segmentada para o filtro MACE.

Os resultados desse experimento foram significativamente melhores evidenciados nas Tabelas 5.23 e 5.24 quando comparados ao respectivos resultados mostrados nas

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
10	0,4280	0,0556	0,1179	0,0091	3,5964	0,5058
20	0,1870	0,0460	0,0607	0,0071	4,1762	0,2290
30	0,1220	0,0304	0,0530	0,0080	4,6150	0,1681
40	0,1200	0,0324	0,0483	0,0066	4,7008	0,1517
50	0,1050	0,0355	0,0479	0,0052	5,1516	0,1183
60	0,1560	0,0393	0,0402	0,0046	4,8968	0,1328
70	0,1780	0,0289	0,0457	0,0070	5,1922	0,1562
80	0,1490	0,0456	0,0414	0,0051	5,1251	0,1403
90	0,0720	0,0199	0,0366	0,0063	5,2812	0,0921
100	0,1660	0,0319	0,0418	0,0064	5,3830	0,1337
110	0,1900	0,0358	0,0365	0,0068	5,2893	0,1361
120	0,1770	0,0446	0,0406	0,0038	5,5785	0,1383
130	0,1740	0,0395	0,0462	0,0051	5,6554	0,1492
140	0,1520	0,0307	0,0407	0,0051	5,7658	0,1149
150	0,1300	0,0315	0,0331	0,0044	5,6769	0,1040
160	0,1350	0,0296	0,0382	0,0056	5,9069	0,1184
170	0,1900	0,0492	0,0435	0,0064	5,9151	0,1457
180	0,1110	0,0301	0,0366	0,0051	6,2530	0,0945
190	0,1190	0,0334	0,0430	0,0053	6,3862	0,1190
200	0,0650	0,0303	0,0294	0,0033	6,3188	0,0682
210	0,1060	0,0235	0,0399	0,0062	6,4208	0,1067
220	0,0860	0,0344	0,0326	0,0045	6,4704	0,0820
230	0,1160	0,0370	0,0377	0,0048	6,4461	0,1075
240	0,0830	0,0478	0,0319	0,0041	6,5188	0,0860
250	0,0950	0,0282	0,0355	0,0042	6,9212	0,0850
260	0,0890	0,0340	0,0324	0,0037	6,9500	0,0916
270	0,0900	0,0328	0,0362	0,0041	7,1105	0,0887
280	0,0680	0,0263	0,0287	0,0044	7,0804	0,0732
290	0,0830	0,0277	0,0310	0,0055	6,9698	0,0869
300	0,0860	0,0373	0,0272	0,0035	6,9266	0,0700
310	0,0540	0,0260	0,0266	0,0033	7,1672	0,0735
320	0,0730	0,0369	0,0212	0,0028	7,1247	0,0574
330	0,0610	0,0210	0,0222	0,0035	7,3241	0,0585
340	0,0510	0,0200	0,0222	0,0030	7,4605	0,0539
350	0,0790	0,0279	0,0248	0,0035	7,1956	0,0829
360	0,0540	0,0298	0,0286	0,0052	7,6940	0,0746

Tabela 5.24: Resultados obtidos variando-se a largura da região segmentada para o filtro MACE-PCA.

Tabelas 5.18 e 5.19 é importante enfatizar o fato de se ter, novamente, obtido melhores resultados para a abordagem com PCA em situações onde a região escolhida para teste






Figura 5.28: Taxa de falsos positivos em função da largura. MACE-PCA em vermelho, MACE em azul.




Figura 5.29: Taxa de falsos negativos em função da largura. MACE-PCA em vermelho, MACE em azul.



era menor (observar Figuras 5.28 e 5.29) e o respectivo OVC para o MACE-PCA se destacava em relação a abordagem MACE tradicional (Figura 5.31).

### 5.3.10 Desempenho em Função do Fator de Escala medindo-se a Relação entre Pico e Desvio Padrão

Esse experimento replica o realizado na seção 5.3.7 diferenciando-se por usar como parâmetro de classificação a relação entre o valor de pico e o desvio padrão. Os resultados obtidos são mostrados nas Tabelas 5.25 e 5.25 e ilustrados nas Figuras 5.32, 5.33, 5.34 e 5.35.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
0,20	0,0100	0,0138	0,9889	0,0045	2,1657	0,7548
0,25	0,2580	0,0372	0,0451	0,0044	3,7319	0,2074
0,30	0,0770	0,0339	0,0266	0,0035	3,9743	0,0843
0,35	0,1420	0,0317	0,0288	0,0026	4,0707	0,1138
0,40	0,1020	0,0330	0,0210	0,0044	4,2061	0,0777
0,45	0,0660	0,0291	0,0222	0,0034	4,3146	0,0675
0,50	0,0900	0,0315	0,0198	0,0030	4,4047	0,0641
0,55	0,0740	0,0344	0,0203	0,0040	4,5237	0,0609
0,60	0,0670	0,0198	0,0248	0,0041	4,7003	0,0597
0,65	0,0970	0,0277	0,0240	0,0031	4,5939	0,0798
0,70	0,0830	0,0333	0,0286	0,0040	4,7732	0,0779
0,75	0,0880	0,0358	0,0271	0,0044	4,7962	0,0754
0,80	0,0760	0,0302	0,0222	0,0032	4,8109	0,0674
0,85	0,0930	0,0333	0,0280	0,0034	4,9314	0,0902
0,90	0,1040	0,0365	0,0276	0,0028	4,9586	0,0841
0,95	0,1080	0,0300	0,0287	0,0033	5,1118	0,0928
1,00	0,1130	0,0357	0,0320	0,0029	5,2679	0,0986

Tabela 5.25: Resultados obtidos variando-se a escala da região segmentada para o filtro MACE.

Parâmetro	Falsos negativos		Falsos positivos		Limiar de classificação	OVC
	$\mu$	$\sigma$	$\mu$	$\sigma$		
0,20	0,1270	0,0333	0,0260	0,0025	3,7820	0,0924
0,25	0,1010	0,0255	0,0249	0,0039	4,0542	0,0804
0,30	0,0400	0,0324	0,0197	0,0029	4,2854	0,0432
0,35	0,1140	0,0298	0,0266	0,0045	4,4469	0,0850
0,40	0,0730	0,0333	0,0252	0,0044	4,6394	0,0647
0,45	0,0630	0,0313	0,0262	0,0040	4,7722	0,0600
0,50	0,0820	0,0311	0,0241	0,0036	4,9471	0,0584
0,55	0,0550	0,0355	0,0253	0,0044	5,0304	0,0588
0,60	0,0590	0,0255	0,0268	0,0042	5,2783	0,0558
0,65	0,0970	0,0236	0,0267	0,0029	5,1725	0,0777
0,70	0,0900	0,0321	0,0363	0,0055	5,4373	0,0865
0,75	0,0790	0,0308	0,0328	0,0050	5,4759	0,0799
0,80	0,0720	0,0238	0,0291	0,0047	5,5111	0,0724
0,85	0,0950	0,0383	0,0324	0,0039	5,6855	0,0931
0,90	0,1080	0,0358	0,0341	0,0042	5,7164	0,0908
0,95	0,0850	0,0330	0,0332	0,0041	5,9394	0,0946
1,00	0,1370	0,0482	0,0387	0,0039	6,2303	0,1136

Tabela 5.26: Resultados obtidos variando-se a escala da região segmentada para o filtro MACE-PCA.

Este experimento quando comparado com seu equivalente abordado na Seção 5.3.10 apresenta resultados melhores (menor OVC e menores taxas de erro) denotando a superioridade do uso da relação entre o valor máximo e o desvio padrão em detrimento do coeficiente de correlação com um modelo. É importante notar o fato do desempenho do MACE-PCA ter se mantido superior ao do MACE clássico em situações onde o fator aplicado a escala das imagens de prova era menor (Figuras 5.32 e 5.33) fato esse denotado pelos melhores índices de OVC obtidos nessas condições e mostrados na Figura 5.35.




Figura 5.32: Taxa de falsos positivos em função da escala. MACE-PCA em vermelho, MACE em azul.




Figura 5.33: Taxa de falsos negativos em função da escala. MACE-PCA em vermelho, MACE em azul.




Figura 5.34: Limiar de classificação em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'.  
+




Figura 5.35: OVC em função da escala. Os marcadores são os seguintes: filtro MACE 'x' e filtro MACE-PCA '+'.  
+

# Conclusão

Dentre os processos emergentes para identificação biométrica a íris se destaca pelo elevado grau de angularidade tornando-se foco de diversos trabalhos relacionados ao reconhecimento biométrico. Nesta abordagem, é necessária cooperação quase total de um indivíduo submetido ao processo de identificação para que se obtenham bons resultados sem mencionar a necessidade de equipamentos muito sofisticados e de boa resolução para o processo de aquisição de imagens. Nesse contexto, surge o desafio de se gerar um modelo capaz de tratar situações adversas nas quais a íris sofre distorções ou misturas com ruído, contextualizando-se assim principais desafios desse trabalho.

O primeiro desafio se fez na escolha de um método apropriado para extração de características relevantes de um conjunto limitado de padrões e devido a características relacionadas ao erro quadrático médio mínimo e a compactação da maior parte da informação sobre a variância de um conjunto de treinos em um grupo reduzido de vetores, escolheu-se a análise de componentes principais, a qual possibilitou a redução de um conjunto de padrões em um grupo menor sem perda de informação.

O segundo desafio consistiu na escolha adequada de uma métrica que pudesse ser eficaz na determinação da qualidade do classificador, verificou-se a inadequação de métricas que levem em consideração apenas a taxa de acertos em situações nas quais o conjunto de teste apresenta padrões em proporção desequilibrada em relação ao conjunto de rejeição e aprovação, como exemplo imaginemos um classificador que rejeite 80% dos padrões positivos e quase todos os negativos, portanto um péssimo classificador, se 90% dos padrões testados forem de classes negativas ainda assim teremos a ilusão de que o classificador tem elevado desempenho. Tal situação faz-se presente nesse trabalho devido aos testes de verificação onde na maioria dos casos se tem apenas um padrão que deve ser classificado positivamente em um conjunto de dezenas de impostores. para tratar esse desafio usou-se duas métricas que expressavam a taxa de erro dos classificadores em função do número de falsos positivos e falsos negativos.

Após determinadas as métricas de desempenho, a barreira encontrada foi o desafio de encontrar um método para detecção de picos de energia no plano de correlação dos quais dois foram expostos nesse trabalho. o primeiro consistia numa medida de

similaridade do pico de energia obtido com um padrão modelo pré-determinado. O segundo consistia numa simples relação entre o valor de pico e o desvio padrão obtido na saída do filtro de correlação restando encontrar uma maneira que expressasse quantitativamente o quão uma medida poderia ser melhor que a outra para classificação. Nesse contexto modelou-se os resultados obtidos em suas respectivas distribuições Gaussianas possibilitando a determinação do melhor limiar possível de classificação. As regiões de aprovação e rejeição puderam assim ser determinadas e uma métrica de erro aqui denominada OVC pode ser usada como medida qualitativa do classificador, tal métrica carrega em seu âmago a ideia de análise de histograma abordada no início desse trabalho condensando, numericamente, a intersecção obtida entre as regiões de aprovação e rejeição fornecendo um valor que serve de parâmetro de julgamento da qualidade da característica escolhida para classificação.

Escolhidos os mecanismos de mensuração e qualificação, resta como desafio a exploração de situações nas quais o modelo escolhido pode ser aplicado gerando resultados melhores do que aqueles obtidos pelos filtros sem incorporar a análise de componentes principais e o resultado mais interessante consistiu no desempenho dos classificadores em situações adversas onde a informação presente nos padrões de entrada e de certa forma limitada, seja por um fator de escala, simulando a distância de aquisição, ou pela variação do tamanho da região escolhida dos padrões para teste. Essas avaliações mostraram o potencial do uso da análise de componentes principais usadas em conjunto com filtros nas condições de baixa informação dos padrões usados, sem representar perda de desempenho significativa no restante das condições. Tal fato mostra como a análise de componentes principais pode ser uma ferramenta de valor em algumas situações e, sem dúvida, tal análise é um dos objetivos concretizados desse trabalho.

Notou-se nos experimentos a excelente habilidade da análise de componentes principais na extração de informação relevante e como seu uso afeta pouco o desempenho do classificador em situações convencionais e melhora seu desempenho em situações especiais trazendo um conjunto de novas análises possíveis e que servem de foco para trabalhos posteriores especialmente no que se refere a modelagem e determinação paramétrica ótima de uso. Tendo esse trabalho como ponto de partida uma nova série de possibilidades se abrem, sendo essas foco potencial para trabalhos futuros, dentre essas pode-se citar: a criação de uma modelagem matemática que expresse o comportamento observados para os limiares de classificação em função de parâmetro como resolução e entropia da informação dos padrões de treino e teste, a criação de um modelo matemático eficiente para detecção de picos de energia e uma proposta mais detalhada de métricas adequadas para medida de desempenho de um classificador, e uma análise computacional paramétrica que determine os melhores valores para os parâmetros dos



classificadores.

Neste trabalho, utilizamos um conjunto de métricas adequadas para medida de desempenho, um método de classificação eficiente para situações adversas relacionadas a quantidade de informação presente nos padrões de teste e um conjunto de possibilidades para trabalhos futuros tornando-se ponto de partida para uma série de temas futuros. Não deve-se esquecer da abordagem da análise espectral através do uso da componente modular da DFT a qual acrescentou invariância ao deslocamento ao filtro SDF. Este fato deve-se a uma propriedade interessante da DFT na qual deslocamentos espaciais aparecem no domínio espectral como alterações de fase, portando, para tornar um sistema invariante ao deslocamento basta se calcule o módulo da DFT e se dispense a fase.

# Referências Bibliográficas

- [1] Anil K. Jain, Robert P. W. Duin, and Jianchang Mao. Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis And Machine Intelligence*, 22(1):4–37, jan 2000.
- [2] Yang Liu and Xinglin Chen. An intelligent nondestructive detection method based on wavelet processing and principal component analysis. In *Proceedings of the International Conference on Industrial Mechatronics and Automation*, pages 71–75, may 2010.
- [3] C. Xie, M. Savvides, and B. V. K. Vijaya Kumar. Redundant class-dependence feature analysis based on correlation filters using frgc2.0 data. In *Proceedings of the Conference on Computer Vision and Pattern Recognition*, page 153, San Diego, CA, USA, June 2005.
- [4] Tong Liu, Guocai Zhu, Chao Zhang, and Pengwei Hao. Fingerprint indexing based on singular point correlation. In *Proceedings of the IEEE International Conference on Image Processing*, pages 293–6, Genoa, Italy, September 2005.
- [5] J. Thornton, M. Savvides, and B. V. K. Vijaya Kumar. A bayesian approach to deformed pattern matching of iris images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29:596–606, 2007.
- [6] Hennings Yeomans and B. V. K. Vijaya Kumar. Palmprint classification using pattern-specific segmentation and optimal correlation filters. *IEEE Transactions on Information Forensics and Security*, 2:613–622, 2007.
- [7] S. Watanabe. *Pattern Recognition: Human and Mechanical*. New York, 1985.
- [8] Rogério Silva Rodrigues. Reconhecimento de padrões de falhas em interiores de aeronaves, 2009.
- [9] An automated approach for segmenting and classifying a large sample of multi-date landsat imagery for pan-tropical forest monitoring. *Remote Sensing of Environment*, 115(12):3659–3669, 2011.

- [10] Vivian F. Renó, Evlyn M. L. M. Novo, Chieno Suemitsu, Camilo D. Rennó, and Thiago S.F. Silva. Assessment of deforestation in the lower amazon flood-plain using historical landsat mss/tm imagery. *Remote Sensing of Environment*, 115(12):3446–3456, 2011.
- [11] Heng Fui Liao and Dino Isa. Feature selection for support vector machine-based face-iris multimodal biometric system. *Expert Systems with Applications*, 38(9):11105 – 11111, 2011.
- [12] Xiao-Yuan Jing, Yong-Fang Yao, David Zhang, Jing-Yu Yang, and Miao Li. Face and palmprint pixel level fusion and kernel dcv-rbf classifier for small sample biometric recognition. *Pattern Recognition*, 40(11):3209 – 3224, 2007.
- [13] Nicolae Duta. A survey of biometric technology based on hand shape. *Pattern Recognition*, 42(11):2797 – 2806, 2009.
- [14] B. V. K. Vijaya Kumar, Abhijit Mahalanobis, and Richard Juday. *Correlation Pattern Recognition*. Cambridge University Press, New York, 2nd edition, 2005.
- [15] B. V. K. Vijaya Kumar. Tutorial survey of composite filter designs for optical correlators. *Applied Optics*, 31:4773–4801, 1992.
- [16] Abhuit Mahalanobis, Arthur V. Forman Jr., Nathalie Day, Mark Bower, and Rich Cherry. Multi-class sar atr using shift-invariant correlation filters. *Pattern Recognition*, 27(4):619–626, 1994.
- [17] Jason Thornton, Marios Savvides, and B. Vijayakumar. Robust iris recognition using advanced correlation techniques. In *Image Analysis and Recognition*, volume 3656, pages 1098–1105. 2005.
- [18] B. V. K. Vijaya Kumar, Marios Savvides, Chunyan Xie, Krithika Venkataramani, Jason Thornton, and Abhijit Mahalanobis. Biometric verification with correlation filters. *Applied Optics*, 43:391–402, 2004.
- [19] G. Turin. An introduction to matched filters. *IRE Transactions on Information Theory*, 6(3):311–329, june 1960.
- [20] Charles F. Hester and David Casasent. Multivariant technique for multiclass pattern recognition. *Applied Optics*, 19:1758–1761, 1980.
- [21] Institute of Automation (CASIA) Chinese Academy of Sciences. Casia iris image database.

- [22] Peter E. Hart Richard O. Duda and David G. Stork. *Pattern Classification*. Wiley Interscience, 2nd edition, 2000.
- [23] Christopher M. Bishop. *Pattern recognition and machine learning*. Springer, 1st ed. 2006. corr. 2nd printing edition, 2006.
- [24] Rafael C. Gonzalez and Richard E. Woods. *Digital Image Processing*. Pearson Education, New Jersey, 3rd edition, 2008.
- [25] Sergios Theodoridis and Konstantinos Koutroumbas. *Pattern Recognition*. Elsevier, 2nd edition, 2003.
- [26] King-Sun Fu. Recent developments in pattern recognition. *IEEE Transaction on Computing*, 29(10):845–854, October 1980.
- [27] J. Kim and C. Scott. Robust kernel density estimation. In *Proceedings of the International Conference on Acoustics, Speech and Signal Processing*, pages 3381–3384, 2008.
- [28] J. Kim and C. Scott. Performance analysis for  $l_2$  kernel classification. In D. Koller, D. Schuurmans, Y. Bengio, and L. Bottou, editors, *Advances in Neural Information Processing Systems 21*, pages 833–840. 2009.
- [29] Philipp K. Janert. *Gnuplot in Action: Understanding Data with Graphs*. Manning Publications Co., Greenwich, CT, USA, 2009.
- [30] Furao Shen and Osamu Hasegawa. A fast nearest neighbor classifier based on self-organizing incremental neural network. *Neural Network*, 21(10):1537–1547, December 2008.
- [31] Dan Li, Hong Gu, and Liyong Zhang. A fuzzy c-means clustering algorithm based on nearest-neighbor intervals for incomplete data. *Expert System Applied*, 37(10):6942–6947, October 2010.
- [32] Hae Yong Kim. Rotation-discriminating template matching based on fourier coefficients of radial projections with robustness to scaling and partial occlusion. *Pattern Recognition*, 43(3):859–872, March 2010.
- [33] Yi-Hsien Lin and Chin-Hsing Chen. Template matching using the parametric template vector with translation, rotation and scale invariance. *Pattern Recognition*, 41(7):2413–2421, 2008.

- [34] Alexander Sibiriyakov and Mirosław Bober. Real-time facial feature detection by statistical template matching. In *Proceedings of the International Conference on Signal, Speech and Image Processing*, pages 101–106, Stevens Point, Wisconsin, USA, 2005.
- [35] Emilio Del-Moral-Hernandez, Humberto Sandmann, and Gleison Araújo. Context dependent pattern recognition: a framework for hybrid architectures bridging chaotic neural networks based on recursive processing elements and symbolic information. In *Proceedings of the International Joint Conference on Neural Networks*, pages 3334–3341, Piscataway, NJ, USA, 2009.
- [36] Roberto Tronci, Giorgio Giacinto, and Fabio Roli. Combination of experts by classifiers in similarity score spaces. In *Structural, Syntactic, and Statistical Pattern Recognition*, volume 5342, pages 821–830. 2008.
- [37] A. Jalil, T. A. Cheema, A. Manzar, and I. M. Qureshi. Rotation and gray-scale-invariant texture analysis using radon and differential radon transforms based hidden markov models. *IET Image Processing*, 4(1):42–48, 2010.
- [38] R. J. Dekker. Texture analysis of urban areas in ers sar imagery for map updating. In *IEEE/ISPRS Joint Workshop in Remote Sensing and Data Fusion over Urban Areas*, pages 226–230, 2001.
- [39] Richard G. Lyons. *Understanding Digital Signal Processing*. Prentice Hall, New Jersey, 2 edition, 2004.
- [40] James W. Cooley and John W. Tukey. An algorithm for the machine calculation of complex fourier series. *Mathematics of Computation*, 19(90):297–301, April 1965.
- [41] Shlens Jonathon. A tutorial on principal component analysis. Disponível em: <http://www.snl.salk.edu/shlens/pub/notes/pca.pdf>. Acesso em: outubro de 2012.
- [42] Sofia Mosci, Lorenzo Rosasco, and Alessandro Verri. Dimensionality reduction and generalization. In *Proceedings of the International Conference on Machine Learning*, pages 657–664, Corvallis, Oregon, USA, 2007.
- [43] D. Tufts and R. Kumaresan. Singular value decomposition and improved frequency estimation using linear prediction. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 30(4):671 – 675, aug 1982.
- [44] J. MacQueen. Some methods for classification and analysis of multivariate observations. In Lucien M. Le Cam and Jerzy Neyman, editors, *Proceedings of the*

- Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, pages 281–297. 1967.
- [45] H. Steinhaus. Sur la division des corps matériels en parties. In *Bull. Acad. Polon. Sci*, volume 1, pages 801–804. 1956.
- [46] R. Nock and F. Nielsen. On weighting clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(8):1223–1235, aug. 2006.
- [47] L. Kaufman and P.J. Rousseeuw. Clustering by means of medoids. *Statistical Data Analysis Based on the L-Norm and Related Methods*, pages 405–416, 1987.
- [48] D. Arthur and S. Vassilvitskii. K-means++: The advantages of careful seeding. *Proceedings of the Symposium on Discrete Algorithms*, pages 1027–1035, 2007.
- [49] Anil Kumar Sao and B. Yegnanarayana. Face verification using correlation filters and autoassociative neural networks. In *Proceedings of the International Conference on Intelligent Sensing and Information Processing*, pages 364–367, Melbourne, Australia, December 2004.
- [50] Paulo S. R. Diniz, Eduardo A. B. da Silva, and Sergio L. Netto. *Digital Signal Processing: System Analysis and Design*. Cambridge University Press, 2 edition, September 2010.
- [51] B. V. K. Vijaya Kumar, M. Savvides, K. Venkataramani, and C. Xie. Spatial frequency domain image processing for biometric recognition. In *Proceedings of the International Conference on Image Processing*, pages 97–100, Rochester, New York, USA, September 2002.
- [52] A. Mahalanobis, B. V. K. Vijaya Kumar, and D. Casasent. Minimum average correlation energy filters. *Applied Optics*, 26:3633–3640, 1987.
- [53] Robert C. Wrede and Murray Spiegel. *Schaum’s Outline of Advanced Calculus*. McGRAW-HILL, 2 edition, 2002.
- [54] Joseph L. Rodgers and Alan W. Nicewander. Thirteen Ways to Look at the Correlation Coefficient. *The American Statistician*, 42(1):59–66, 1988.
- [55] Henry F. Inman and Edwin L. Bradley. The overlapping coefficient as a measure of agreement between probability distributions and point estimation of the overlap of two normal densities. *Communications in Statistics - Theory and Methods*, 18(10):3851–3874, 1989.

- [56] A. Bhattacharyya. On a measure of divergence between two statistical populations defined by their probability distributions. *Bulletin of the Calcutta Mathematical Society*, 35:99–109, 1943.
- [57] Metin Akay. *Wiley Encyclopedia of Biomedical Engineering*. Wiley, 2000.
- [58] J.G. Daugman. High confidence visual recognition of persons by a test of statistical independence. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11):1148–1161, nov 1993.
- [59] Luciano Lima de Oliveira. Segmentação da íris em imagens oculares para aplicações de reconhecimento biométrico de indivíduos: uma nova abordagem utilizando redes neurais, 2009.
- [60] M. G. F. Costa L. O. Lima and C. F. F. Costa Filho. Nova proposta de extração de características da Íris utilizando o espaço hsi. *Congresso Brasileiro de Engenharia Biomédica*, pages 1405 –1409, 2008.
- [61] Julius O. Smith III. *Mathematics of the Discrete Fourier Transform (DFT)*. Stanford University, Stanford - California, 2002.