UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ARTES, CIÊNCIAS E HUMANIDADES
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

JONAS MENDONÇA TARGINO

**Reconstrução de oclusões parciais em imagens de face visando o
reconhecimento biométrico**

São Paulo

2019

JONAS MENDONÇA TARGINO

**Reconstrução de oclusões parciais em imagens de face visando o
reconhecimento biométrico**

Dissertação apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Sistemas de Informação.

Área de concentração: Metodologia e Técnicas da Computação

Versão corrigida contendo as alterações solicitadas pela comissão julgadora em 10 de dezembro de 2018. A versão original encontra-se em acervo reservado na Biblioteca da EACH-USP e na Biblioteca Digital de Teses e Dissertações da USP (BDTD), de acordo com a Resolução CoPGr 6018, de 13 de outubro de 2011.

Orientador: Prof. Dr. Clodoaldo Aparecido de Moraes Lima

Coorientador: Profa. Dra. Sarajane Marques Peres

São Paulo

2019

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

CATALOGAÇÃO-NA-PUBLICAÇÃO

(Universidade de São Paulo. Escola de Artes, Ciências e Humanidades. Biblioteca)
CRB 8 - 4936

Targino, Jonas Mendonça

Reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico / Jonas Mendonça Targino ; orientador, Clodoaldo Aparecido de Moraes Lima ; coorientadora, Sarajane Marques Peres. – 2019.

297 f. : il

Dissertação (Mestrado em Ciências) - Programa de Pós-Graduação em Sistemas de Informação, Escola de Artes, Ciências e Humanidades, Universidade de São Paulo.

Versão corrigida

1. Reconhecimento de padrões. 2. Inteligência artificial. 3. Biometria. 4. Processamento de imagens. 5. Percepção da face. I. Lima, Clodoaldo Aparecido de Moraes, orient. II. Peres, Sarajane Marques, coorient. III. Título

CDD 22.ed.– 006.4

Dissertação de autoria de Jonas Mendonça Targino, sob o título “**Reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico**”, apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo, para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Sistemas de Informação, na área de concentração Metodologia e Técnicas da Computação, aprovada em 10 de dezembro de 2018 pela comissão julgadora constituída pelos doutores:

Prof. Dr. Clodoaldo Aparecido de Moraes Lima

Instituição: Escola de Artes, Ciências e Humanidades - Universidade de São Paulo
Presidente

Prof. Dr. Adilson Gonzaga

Instituição: Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo

Prof. Dr. Hemerson Pistori

Instituição: Universidade Católica Dom Bosco

Prof. Dr. Lee Luan Ling

Instituição: Universidade Estadual de Campinas

Dedico este trabalho aos meus pais, Manoel e Josivânia, que me ensinaram que o empenho, a persistência e a honestidade nos levam aos mais diversos sonhos. Graças ao apoio, incentivo e paciência de minha família consigo perceber minha contribuição mediante este trabalho para com o meio científico. Também dedico ao meu avô Julio Targino (in Memoriam), o qual prometi que um dia eu iria ser Doutor, esse dia está chegando e logo poderemos compartilhar desse momento.

Agradecimentos

Primeiramente, gostaria de agradecer a Deus pelo dom da vida, por ter me capacitado a vencer mais esse desafio, por sempre colocar suas mãos e me cobrir com o seu santo manto, me livrando de todo o mal e me dando refúgio em momentos de angústia. Sem Deus tudo que foi feito nesta dissertação ainda estaria por fazer.

Agradeço aos meus pais Manoel e Josivânia, por todo o apoio, incentivo e esforço que fizeram durante o desenvolvimento deste trabalho. Abdicando de inúmeras coisas para me verem onde estou hoje, pois mesmo distantes estavam torcendo pela minha vitória e me incentivando a seguir em frente, na busca de meus sonhos, por mais distantes que eles parecessem estar. Se hoje me torno uma nova pessoa é porque aprendi com meus erros, apostei em meus sonhos e em nenhum momento desisti dos mesmos.

Agradeço ao meu irmão Vandilson, sua esposa Thaís e a minha tia Glória, por torcerem e rezarem pela minha vitória. Os quais se orgulham e compartilham de minhas aspirações, compartilhando comigo a satisfação de subir mais um degrau frente à ciência.

De modo especial agradeço ao meu orientador, Prof. Dr. Clodoaldo Aparecido de Moraes Lima, e a minha coorientadora, Profa. Dra. Sarajane Marques Peres pela orientação e apoio para o desenvolvimento deste trabalho de mestrado. Ambos sempre demonstraram disponibilidade para esclarecer eventuais dúvidas, fornecer sugestões e conselhos que foram essenciais para elaboração deste texto de dissertação. Com a ajuda dessa dupla consegui enxergar potenciais que nunca pensei que existiam dentro de mim.

A todos os amigos que conviveram comigo no Grupo de Inteligência Artificial (GrIA), pelo companheirismo, respeito mútuo e compartilharem inúmeras experiências e tarefas. De modo especial ao Diego Neves, Fernando Costa, Lígia Moreno, Renan Vinicius, Henrique Passos, Jozias Rolim, Williane Rodrigues e Jonnathann Finizola.

Agradeço também ao professor Luciano Digiampietri por dialogar comigo a respeito da vida acadêmica e por ser um exemplo de pessoa a ser seguido.

Também gostaria de agradecer ao meu amigo Josué Gomes, o qual mesmo de longe me proporciona risadas e ideias malucas que as vezes nunca saem do papel.

Por fim, e não menos importante, agradeço a CAPES pelo auxílio financeiro que permitiu com que fosse possível desenvolver este trabalho.

"Julgue seu sucesso pelas coisas que você teve que renunciar para conseguir"

(Dalai Lama)

Resumo

Targino, Jonas Mendonça. **Reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico**. 2019. 297 f. Dissertação (Mestrado em Ciências) – Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2019.

Há um crescente incentivo ao uso da tecnologia biométrica para melhorar, e até mesmo substituir os métodos tradicionais de segurança. O campo da Biometria refere-se a uma grande variedade de tecnologias usadas para identificar ou verificar a identidade de uma pessoa por meio da mensuração e análise de vários aspectos físicos e comportamentais do ser humano. Modalidades biométricas são características extraídas do corpo humano, que são únicas para cada indivíduo e que podem ser usadas para estabelecer sua identidade numa população. As principais modalidades biométricas empregadas na literatura são: impressão digital, face, voz, palma da mão e íris. Dentre as modalidades biométricas, a face é a mais comumente vista e usada em nossa vida diária. Em aplicações de mundo real, sistemas de reconhecimento facial, frequentemente, têm que lidar com condições não controladas e não previsíveis, tais como mudança na iluminação, pose, expressão e oclusão, as quais introduzem variações intraclasse e degradam a performance do reconhecimento. Comparada com problemas de pose, iluminação e expressão, o problema relacionado à oclusão é relativamente pouco estudado na área. As abordagens empregadas para atacar o problema de reconhecimento facial na presença de oclusões parciais podem ser categorizadas em: i) abordagens baseadas em reconstrução, que formulam o reconhecimento biométrico baseado em imagens de face parcialmente ocluídas como um problema de reconstrução; ii) abordagens baseadas em correspondência local, que extraem características locais da face; iii) abordagens baseadas em características insensíveis, que extraem características da face que são robustas à oclusão. O objetivo desta dissertação é realizar um estudo comparativo detalhado das abordagens baseadas em reconstrução visando reconhecimento biométrico facial na presença de oclusão. As abordagens baseadas em reconstrução foram aplicadas a duas bases de dados (*AR* e *Yale*) contendo quatro tipos diferentes de oclusões e avaliadas usando a performance obtida no reconhecimento biométrico. Com base no estudo comparativo realizado, foram propostas três técnicas baseadas em reconstrução, que correspondem a uma modificação e/ou combinação de técnicas já conhecidas na literatura. Os resultados experimentais mostraram que as técnicas propostas alcançaram desempenhos melhores ou similares as técnicas descritas na literatura.

Palavras-chaves: Sistemas Biométricos, Reconhecimento Facial, Detecção de Oclusão Facial, Reconstrução de Face Parcialmente Ocluída, Ambiente não controlado.

Abstract

Targino, Jonas Mendonça. **Reconstruction of partial occlusions in face images for biometric recognition**. 2019. 297 p. Dissertation (Master of Science) – School of Arts, Sciences and Humanities, University of São Paulo, São Paulo, 2019.

There is a growing incentive to use biometric technology to improve, even replace, traditional security methods. The field of Biometrics refers to a wide variety of technologies used to identify or verify a person's identity by measuring and analyzing various physical and behavioral aspects of the human being. Biometric modalities are characteristics drawn from the human body, which are unique to each individual and can be used to establish their identity in a population. The main biometric modalities used in the literature are: fingerprint, face, voice, palm, and iris. Among the biometric modalities, the face is the most commonly seen and used in our daily life. In real-world applications, facial recognition systems often have to deal with uncontrolled and unpredictable conditions such as change in illumination, pose, expression, and occlusion, which introduce intraclass variations and degrade recognition performance. Compared with problems of pose, illumination and expression, the problem related to occlusion is relatively little studied in the area. The approaches used to tackle facial recognition in the presence of partial occlusions can be categorized into: (i) reconstruction-based approaches that formulate recognition of occluded faces as a reconstruction problem; ii) approaches based on local correspondence, which extract local face characteristics; iii) approaches based on insensitive characteristics, which extract features of the face that are robust to occlusion. The objective of this dissertation is to perform a detailed comparative study of reconstruction-based approaches aiming at facial recognition in the presence of occlusion. Reconstruction-based approaches were applied to two databases (AR and Yale) containing four different types of occlusions and evaluated using the performance obtained in the biometric recognition. Based on the comparative study, three reconstruction-based techniques were proposed, which correspond to a change in the formulation and/or combination of techniques already known in the literature. The experimental results showed that the proposed techniques achieved better or similar performances than the techniques described in the literature.

Keywords: Biometric Systems, Facial Recognition, Facial Occlusion Detection, Partially Occluded Face Reconstruction, Uncontrolled Environment.

Lista de figuras

Figura 1 – Ilustração de diferentes tipos de oclusões parciais: (a) oclusões faciais comuns em nossa rotina diária; (b) oclusões faciais relacionadas a questões de segurança	37
Figura 2 – Módulos de um sistema biométrico	45
Figura 3 – Processo de identificação facial	46
Figura 4 – Verificação facial	47
Figura 5 – Exemplo do processo de verificação e identificação	47
Figura 6 – Exemplos de algumas modalidades biométricas	49
Figura 7 – Etapas necessárias para o reconhecimento de uma face sem oclusão e com oclusão	52
Figura 8 – Tipos de variações advindas de ambientes semi-controlados	54
Figura 9 – Exemplo de construção de uma imagem integral. verde = 2, amarelo = 2+3, laranja = 2 + 4, e azul = 2+3+4+5	56
Figura 10 – Cálculo da soma de um retângulo	56
Figura 11 – Exemplos de características de Haar	57
Figura 12 – Esquema de classificação em cascata do Viola-Jones	58
Figura 13 – Exemplos de faces após a aplicação da técnica <i>Skin Tone</i>	59
Figura 14 – Exemplos de imagens faciais parcialmente ocluídas provenientes da base AR	61
Figura 15 – Curvas de FAR e FRR, com ponto de intersecção EER	67
Figura 16 – Estrutura de uma matriz de confusão	68
Figura 17 – Esquema do BMA	76
Figura 18 – Detecção da parte ocluída com a técnica de detecção por blocos . . .	77
Figura 19 – Projeção de uma imagem no subespaço	78
Figura 20 – Exemplo de formação da imagem média dado um conjunto de imagens	79
Figura 21 – Exemplos de 10 <i>eigenfaces</i> da base de dados AR com 100 indivíduos .	81
Figura 22 – Exemplo do processo de reconstrução com o Fast Recursive PCA . .	87
Figura 23 – Diagrama de fluxo do processo de reconstrução utilizando a técnica FRPCA	88
Figura 24 – Treinamento da técnica Fast Robust PCA	88

Figura 25 – FRPCA e seu comportamento frente a detecção da oclusão a cada iteração	90
Figura 26 – Exemplos de 10 fisherfaces da base de dados <i>AR</i>	92
Figura 27 – Parte ocluída e aplicação das bordas na região ocluída, e por último a topologia do grafo de Poisson	95
Figura 28 – Estrutura da técnica SRC com Grafo de Poisson	97
Figura 29 – Estrutura de uma Transformada Wavelet	100
Figura 30 – Imagens obtidas após a decomposição Wavelet 2D	101
Figura 31 – Exemplo de classificação do K-NN com duas classes e $K = 6$	102
Figura 32 – Estrutura de uma Rede Neural ELM	103
Figura 33 – Problema de classificação binário com SVM	105
Figura 34 – Esquema proposto nesta dissertação	107
Figura 35 – Estrutura da técnica SRC com <i>Fast Recursive PCA</i>	110
Figura 36 – Topologia do grafo Laplaciano	111
Figura 37 – Estrutura da técnica SRC com Grafo Laplaciano	113
Figura 38 – Estrutura da técnica SSIMGL	115
Figura 39 – Exemplos de imagens das bases de dados <i>AR</i> e <i>Yale</i>	117
Figura 40 – Exemplos de variações das imagens capturadas presentes na base de dados <i>AR</i>	117
Figura 41 – Detecção da face utilizando o algoritmo Viola-Jones	118
Figura 42 – Imagens da base de dados <i>Yale</i> e as respectivas máscaras de oclusão adicionadas	119
Figura 43 – Detecção dos pixels ocluídos com as técnicas de detecção da oclusão parcial	121
Figura 44 – Acurácia de detecção	121
Figura 45 – Máscaras de oclusões obtidas em algumas imagens da base de dados <i>AR</i>	122
Figura 46 – Máscara de oclusão após a aplicação dos filtros morfológicos	122
Figura 47 – Comportamento do SVM ao se variar os valores de σ	126
Figura 48 – Acurácia obtida por grupo usando os coeficientes de aproximação do nível 3 de decomposição e os classificadores KNN, ELM e SVM	127
Figura 49 – Exemplos de imagens reconstruídas de dois indivíduos de acordo com os grupos da base <i>AR</i>	129

Figura 50 – Acurácia obtida na base de dados AR usando classificador KNN e coeficientes de aproximação do nível 3 de decomposição da TW . . .	132
Figura 51 – Acurácia obtida na base de dados AR usando classificador KNN e coeficientes de aproximação do nível 2 de decomposição da TW . . .	133
Figura 52 – Acurácia obtida na base de dados AR usando classificador KNN e coeficientes de aproximação do nível 1 de decomposição da TW . . .	133
Figura 53 – Acurácia obtida na base de dados AR usando classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW . . .	134
Figura 54 – Acurácia obtida na base de dados AR usando classificador ELM e coeficientes de aproximação do nível 2 de decomposição da TW . . .	135
Figura 55 – Acurácia obtida na base de dados AR usando classificador ELM e coeficientes de aproximação do nível 1 de decomposição da TW . . .	136
Figura 56 – Acurácia obtida na base de dados AR usando classificador SVM e coeficientes de aproximação do nível 3 de decomposição da TW . . .	136
Figura 57 – Acurácia obtida na base de dados AR usando classificador SVM e coeficientes de aproximação do nível 2 de decomposição da TW . . .	137
Figura 58 – Acurácia obtida na base de dados AR usando classificador SVM e coeficientes de aproximação do nível 1 de decomposição da TW . . .	138
Figura 59 – Ganhos obtidos pelas técnicas baseadas em subespaço e classificador KNN ao variar os níveis de decomposição da TW	139
Figura 60 – Ganhos obtidos pelas técnicas baseadas em subespaço e classificador ELM ao variar os níveis de decomposição da TW	139
Figura 61 – Ganhos obtidos pelas técnicas baseadas em subespaço e classificador SVM ao variar os níveis de decomposição da TW	140
Figura 62 – Distribuição das taxas de erro geradas pela técnica <i>Recursive</i> PCA usando o classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW	141
Figura 63 – Distribuição das taxas de erro geradas pela técnica Gappy PCA usando o classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW	142

Figura 64 – Distribuição das taxas de erro geradas pela técnica SRC com <i>Fast Recursive</i> PCA usando o classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW	143
Figura 65 – Distribuição dos erros por Classes para cada grupo da base AR usando classificador ELM e a técnica Recursive PCA	144
Figura 66 – Distribuição dos erros por Classes para cada grupo da base AR usando classificador ELM e a técnica técnica Gappy PCA	144
Figura 67 – Distribuição dos erros por Classes para cada grupo da base AR usando classificador ELM e a técnica técnica SRC Fast Rec PCA	145
Figura 68 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica <i>Asymmetrical</i> PCA	147
Figura 69 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Fisherfaces	148
Figura 70 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Fast Robust PCA	149
Figura 71 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica PCA	150
Figura 72 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Gappy PCA	150
Figura 73 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica <i>Recursive</i> PCA	151
Figura 74 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Fast Recursive PCA	152
Figura 75 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SRC com <i>Fast Recursive</i> PCA	153
Figura 76 – Imagens reconstruídas com as técnicas baseadas em subespaço nos grupos da base Yale	154
Figura 77 – Acurácia com KNN com nível 3 de decomposição da TW nos dois grupos da base Yale	156
Figura 78 – Acurácia com ELM com nível 3 de decomposição da TW nos dois grupos da base Yale	157

Figura 79 – Acurácia com SVM com nível 3 de decomposição da TW nos dois grupos da base Yale	157
Figura 80 – Exemplos de imagens de dois indivíduos reconstruídas com as técnicas baseadas em modelo	159
Figura 81 – Acurácia das técnicas baseadas em modelo com classificador KNN com coeficientes de aproximação do nível 3 da TW nos grupos da base AR .	161
Figura 82 – Acurácia das técnicas baseadas em modelo com classificador KNN com coeficientes de aproximação do nível 2 da TW nos grupos da base AR .	161
Figura 83 – Acurácia das técnicas baseadas em modelo com classificador KNN com coeficientes de aproximação do nível 1 da TW nos grupos da base AR	162
Figura 84 – Acurácia das técnicas baseadas em modelo com classificador ELM com coeficientes de aproximação do nível 3 da TW nos grupos da base AR	162
Figura 85 – Acurácia das técnicas baseadas em modelo com classificador ELM com coeficientes de aproximação do nível 2 da TW nos grupos da base AR	163
Figura 86 – Acurácia das técnicas baseadas em modelo com classificador ELM com coeficientes de aproximação do nível 1 da TW nos grupos da base AR	163
Figura 87 – Acurácia das técnicas baseadas em modelo com classificador SVM com coeficientes de aproximação do nível 3 da TW nos grupos da base AR	164
Figura 88 – Acurácia das técnicas baseadas em modelo com classificador SVM com coeficientes de aproximação do nível 2 da TW nos grupos da base AR	164
Figura 89 – Acurácia das técnicas baseadas em modelo com classificador SVM com nível 1 de decomposição da TW nos quatro grupos presentes na base AR	165
Figura 90 – Ganho das técnicas baseadas em modelo ao utilizar os níveis 1 e 2 de decomposição da TW com classificador KNN	165
Figura 91 – Ganho das técnicas baseadas em modelo ao utilizar os níveis 1 e 2 de decomposição da TW com classificador ELM	166
Figura 92 – Ganho das técnicas baseadas em modelo ao utilizar os níveis 1 e 2 de decomposição da TW com classificador SVM	166
Figura 93 – Distribuição das taxas de erro geradas pela técnica SRC com Grafo de Poisson na base de dados AR	167
Figura 94 – Distribuição das taxas de erro geradas pela técnica SRC com Grafo Laplaciano na base de dados AR	167

Figura 95 – Distribuição das taxas de erro geradas pela técnica SSIMGL na base de dados AR	168
Figura 96 – Erros por classe das três técnicas baseadas em modelo nos quatro grupos presentes na base AR com classificador ELM e nível 3 de decomposição da TW	169
Figura 97 – Classes que apresentaram maior erro para cada grupo da base AR, como também os indivíduos confundidos após classificação com ELM para a técnica SRC GP	170
Figura 98 – Classes que apresentaram maior erro para cada grupo da base AR, como também os indivíduos confundidos após classificação com ELM para a técnica SRC GL	170
Figura 99 – Classes que apresentaram maior erro para cada grupo da base AR, como também os indivíduos confundidos após classificação com ELM para a técnica SSIMGL	171
Figura 100 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SRC juntamente com grafo de Poisson	173
Figura 101 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SRC com grafo Laplaciano	173
Figura 102 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SSIMGL	174
Figura 103 – Imagens reconstruídas com as técnicas baseadas em modelo nos dois grupos da base Yale	175
Figura 104 – Acurácia das técnicas baseadas em modelo com nível 3 de decomposição da TW nos grupos da base Yale com os classificadores ELM, KNN e SVM	177
Figura 105 – Análise comparativa de todas as técnicas de reconstrução nos grupos AR#1 e AR#2 com os classificadores KNN, ELM e SVM utilizando nível 3 de decomposição da TW	178
Figura 106 – Análise comparativa de todas as técnicas de reconstrução nos grupos AR#3 e AR#4 com os classificadores KNN, ELM e SVM utilizando nível 3 de decomposição da TW	179
Figura 107 – Curvas ROC média das técnicas de reconstrução em cada grupo da base AR com classificador ELM	180

Figura 108 – Curva Roc da melhor classe para cada técnica de reconstrução em cada grupo da base AR com classificador ELM	181
Figura 109 – Curva Roc da pior classe para cada técnica de reconstrução em cada grupo da base AR com classificador ELM	182
Figura 110 – Comportamento da SSIM do conjunto ao se aumentar o número indivíduos para geração do espaço de faces	185
Figura 111 – Imagens reconstruídas com as técnicas baseadas em subespaço com espaço de faces gerado a partir das faces de 10 indivíduos	186
Figura 112 – Importância do percentual de representatividade do conjunto	186
Figura 113 – Importância do percentual de representatividade na tarefa de reconstrução de faces após avaliação com classificador ELM e nível 3 de decomposição da TW	187
Figura 114 – Reconstrução com APCA, com o espaço de faces gerado por apenas um indivíduo (o mesmo da reconstrução) com imagens sem variação de iluminação e pose.	188
Figura 115 – Processo de seleção dos artigos	210
Figura 116 – Bases de dados utilizadas pelos estudos selecionados	212
Figura 117 – Matriz de confusão da técnica <i>Asymmetrical</i> PCA na base de dados AR	216
Figura 118 – Matriz de confusão da técnica <i>Fast Recursive</i> PCA na base de dados AR	217
Figura 119 – Matriz de confusão da técnica Fisherfaces na base de dados AR . . .	217
Figura 120 – Matriz de confusão da técnica <i>Fast Robust</i> PCA na base de dados AR	218
Figura 121 – Matriz de confusão da técnica <i>Gappy</i> PCA na base de dados AR . .	218
Figura 122 – Matriz de confusão da técnica PCA na base de dados AR	219
Figura 123 – Matriz de confusão da técnica <i>Recursive</i> PCA na base de dados AR .	219
Figura 124 – Matriz de confusão da técnica SRC com <i>Fast Recursive</i> PCA na base de dados AR	220
Figura 125 – Matriz de confusão da técnica SRC com grafo de Poisson na base de dados AR	220
Figura 126 – Matriz de confusão da técnica SRC com grafo Laplaciano na base de dados AR	221
Figura 127 – Matriz de confusão da técnica SSIMGL na base de dados AR	221

Lista de tabelas

Tabela 1 – Número de características extraídas com a transformada Wavelet de acordo com cada nível de decomposição	125
Tabela 2 – Avaliação das técnicas de reconstrução baseadas em subespaço aplicadas aos grupos da base de dados AR usando RMSE	130
Tabela 3 – Avaliação das técnicas de reconstrução baseadas em subespaço aplicadas aos grupos da base de dados AR usando SSIM	130
Tabela 4 – Avaliação das técnicas de reconstrução baseadas em subespaço aplicadas aos grupos da base de dados AR usando PSNR	131
Tabela 5 – Resultados das métricas usadas para avaliar o desempenho da <i>Fast Recursive</i> PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR	145
Tabela 6 – Resultados das métricas usadas para avaliar o desempenho da <i>Gappy</i> PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR	146
Tabela 7 – Resultados das métricas usadas para avaliar o desempenho da <i>Recursive</i> PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR	146
Tabela 8 – Resultados das métricas usadas para avaliar o desempenho da <i>Recursive</i> PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR	146
Tabela 9 – Análise da técnica após aplicação do limiar EER com classificador ELM	153
Tabela 10 – Resultados de RMSE das técnicas baseadas em subespaço nos grupos da base Yale	155
Tabela 11 – Resultados de PSNR das técnicas baseadas em subespaço nos grupos da base Yale	155
Tabela 12 – Resultados de SSIM das técnicas baseadas em subespaço nos grupos da base Yale	156
Tabela 13 – Resultados de RMSE das técnicas baseadas em modelo	159
Tabela 14 – Resultados de PSNR das técnicas baseadas em modelo	160
Tabela 15 – Resultados de SSIM das técnicas baseadas em modelo	160

Tabela 16 – Métricas de desempenho da técnica SRC GP nos quatro grupos da base AR	171
Tabela 17 – Métricas de desempenho da técnica SRC GL nos quatro grupos da base AR	172
Tabela 18 – Métricas de desempenho da técnica SSIMGL nos quatro grupos da base AR	172
Tabela 19 – Análise da taxa de reconhecimento das técnicas baseadas em modelo após aplicação do limiar EER com classificador ELM	175
Tabela 20 – Resultados de RMSE das técnicas baseadas em modelo nos grupos da base Yale	176
Tabela 21 – Resultados de PSNR das técnicas baseadas em subespaço nos grupos da base Yale	176
Tabela 22 – Resultados de SSIM das técnicas baseadas em modelo nos grupos da base Yale	176
Tabela 23 – Bases de dados de domínio público e algumas especificações	213
Tabela 24 – Taxa de reconhecimento com ELM na base de dados AR com oclusões com nível de decomposição LL3	222
Tabela 25 – Taxa de reconhecimento com ELM na base de dados Yale com oclusões com nível de decomposição LL3	223
Tabela 26 – Taxa de reconhecimento da técnica <i>Asymmetrical</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3	224
Tabela 27 – Taxa de reconhecimento da técnica <i>Fast Recursive</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3	225
Tabela 28 – Taxa de reconhecimento da técnica Fisherfaces com ELM na base de dados AR com oclusões com nível de decomposição LL3	226
Tabela 29 – Taxa de reconhecimento da técnica <i>Fast Robust</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3	227
Tabela 30 – Taxa de reconhecimento da técnica <i>Gappy</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3	228
Tabela 31 – Taxa de reconhecimento da técnica PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3	229

Tabela 32 – Taxa de reconhecimento da técnica <i>Recursive</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3	230
Tabela 33 – Taxa de reconhecimento da Representação Esparsa com <i>Fast Recursive</i> PCA na base de dados AR com ELM com nível de decomposição LL3 .	231
Tabela 34 – Taxa de reconhecimento da base ocluída com ELM na base de dados AR com oclusões com nível de decomposição LL2	232
Tabela 35 – Taxa de reconhecimento da técnica <i>Asymmetrical</i> PCA com ELM nos quatro grupos da base AR com nível de decomposição LL2	233
Tabela 36 – Taxa de reconhecimento da técnica PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2	234
Tabela 37 – Taxa de reconhecimento da técnica Fisherfaces com ELM na base de dados AR com oclusões com nível de decomposição LL2	235
Tabela 38 – Taxa de reconhecimento da técnica <i>Fast Robust</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2 . . .	236
Tabela 39 – Taxa de reconhecimento da técnica <i>Gappy</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2	237
Tabela 40 – Taxa de reconhecimento da técnica <i>Fast Recursive</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2 . . .	238
Tabela 41 – Taxa de reconhecimento da técnica <i>Recursive</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2	239
Tabela 42 – Taxa de reconhecimento da SRC com <i>Fast Recursive</i> PCA na base de dados AR com ELM com nível de decomposição LL2	240
Tabela 43 – Taxa de reconhecimento da base ocluída com ELM na base de dados AR com oclusões com nível de decomposição LL1	241
Tabela 44 – Taxa de reconhecimento da técnica <i>Asymmetrical</i> PCA com ELM nos quatro grupos da base AR com nível de decomposição LL1	242
Tabela 45 – Taxa de reconhecimento da técnica PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1	243
Tabela 46 – Taxa de reconhecimento da técnica Fisherfaces com ELM na base de dados AR com oclusões com nível de decomposição LL1	244
Tabela 47 – Taxa de reconhecimento da técnica <i>Fast Robust</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1 . . .	245

Tabela 48 – Taxa de reconhecimento da técnica <i>Gappy</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1	246
Tabela 49 – Taxa de reconhecimento da técnica <i>Fast Recursive</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1 . . .	247
Tabela 50 – Taxa de reconhecimento da técnica <i>Recursive</i> PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1	248
Tabela 51 – Taxa de reconhecimento da SRC com <i>Fast Recursive</i> PCA na base de dados AR com ELM com nível de decomposição LL1	249
Tabela 52 – Taxa de reconhecimento com KNN na base de dados AR com oclusões com nível de decomposição LL3	250
Tabela 53 – Taxa de reconhecimento com KNN na base de dados Yale com oclusões com nível de decomposição LL3	250
Tabela 54 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Fast Recursive</i> PCA com nível de decomposição LL3	251
Tabela 55 – Taxa de reconhecimento com KNN na base AR com a técnica Fisherfaces com nível de decomposição LL3	251
Tabela 56 – Taxa de reconhecimento com KNN na base AR com a técnica Fast Robust PCA com nível de decomposição LL3	252
Tabela 57 – Taxa de reconhecimento com KNN na base AR com a técnica Gappy PCA com nível de decomposição LL3	252
Tabela 58 – Taxa de reconhecimento com KNN na base AR com a técnica PCA com nível de decomposição LL3	253
Tabela 59 – Taxa de reconhecimento com KNN na base AR com a técnica Recursive PCA com nível de decomposição LL3	253
Tabela 60 – Taxa de reconhecimento com KNN na base AR com a técnica Asymmetrical PCA com nível de decomposição LL3	254
Tabela 61 – Taxa de reconhecimento da técnica SRC com <i>Fast Recursive</i> PCA com classificador KNN com nível de decomposição LL3	254
Tabela 62 – Taxa de reconhecimento da base ocluída com classificador KNN com nível de decomposição LL2	255
Tabela 63 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Fast Recursive</i> PCA com nível de decomposição LL2	255

Tabela 64 – Taxa de reconhecimento com KNN na base AR com a técnica Fisherfaces com nível de decomposição LL2	256
Tabela 65 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Fast Robust</i> PCA com nível de decomposição LL2	256
Tabela 66 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Gappy</i> PCA com nível de decomposição LL2	257
Tabela 67 – Taxa de reconhecimento com KNN na base AR com a técnica PCA com nível de decomposição LL2	257
Tabela 68 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Recursive</i> PCA com nível de decomposição LL2	258
Tabela 69 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Asymmetrical</i> PCA com nível de decomposição LL2	258
Tabela 70 – Taxa de reconhecimento da técnica SRC com <i>Fast Recursive</i> PCA com classificador KNN com nível de decomposição LL2	259
Tabela 71 – Taxa de reconhecimento da base ocluída com classificador KNN com nível de decomposição LL1	259
Tabela 72 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Fast Recursive</i> PCA com nível de decomposição LL1	260
Tabela 73 – Taxa de reconhecimento com KNN na base AR com a técnica Fisherfaces com nível de decomposição LL1	260
Tabela 74 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Fast Robust</i> PCA com nível de decomposição LL1	261
Tabela 75 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Gappy</i> PCA com nível de decomposição LL1	261
Tabela 76 – Taxa de reconhecimento com KNN na base AR com a técnica PCA com nível de decomposição LL1	262
Tabela 77 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Recursive</i> PCA com nível de decomposição LL1	262
Tabela 78 – Taxa de reconhecimento com KNN na base AR com a técnica <i>Asymmetrical</i> PCA com nível de decomposição LL1	263
Tabela 79 – Taxa de reconhecimento da técnica SRC com <i>Fast Recursive</i> PCA com classificador KNN com nível de decomposição LL1	263

Tabela 80 – Taxa de reconhecimento da base ocluída com classificador SVM com nível de decomposição LL3	264
Tabela 81 – Taxa de reconhecimento da técnica <i>Asymmetrical</i> PCA com classificador SVM com nível de decomposição LL3	265
Tabela 82 – Taxa de reconhecimento da técnica <i>Fast Recursive</i> PCA com classificador SVM com nível de decomposição LL3	265
Tabela 83 – Taxa de reconhecimento da técnica Fisherfaces com classificador SVM com nível de decomposição LL3	266
Tabela 84 – Taxa de reconhecimento da técnica <i>Fast Robust</i> PCA com classificador SVM com nível de decomposição LL3	266
Tabela 85 – Taxa de reconhecimento da técnica <i>Gappy</i> PCA com classificador SVM com nível de decomposição LL3	267
Tabela 86 – Taxa de reconhecimento da técnica PCA com classificador SVM com nível de decomposição LL3	267
Tabela 87 – Taxa de reconhecimento da técnica <i>Recursive</i> PCA com classificador SVM com nível de decomposição LL3	268
Tabela 88 – Taxa de reconhecimento da técnica SRC com <i>Fast Recursive</i> PCA com classificador SVM com nível de decomposição LL3	268
Tabela 89 – Taxa de reconhecimento da base ocluída com classificador SVM com nível de decomposição LL2	269
Tabela 90 – Taxa de reconhecimento da técnica APCA com classificador SVM com nível de decomposição LL2	269
Tabela 91 – Taxa de reconhecimento da técnica <i>Fast Recursive</i> PCA com classificador SVM com nível de decomposição LL2	270
Tabela 92 – Taxa de reconhecimento da técnica Fisherfaces com classificador SVM com nível de decomposição LL2	270
Tabela 93 – Taxa de reconhecimento da técnica <i>Fast Robust</i> PCA com classificador SVM com nível de decomposição LL2	271
Tabela 94 – Taxa de reconhecimento da técnica <i>Gappy</i> PCA com classificador SVM com nível de decomposição LL2	271
Tabela 95 – Taxa de reconhecimento da técnica PCA com classificador SVM com nível de decomposição LL2	272

Tabela 96 – Taxa de reconhecimento da técnica <i>Recursive</i> PCA com classificador SVM com nível de decomposição LL2	272
Tabela 97 – Taxa de reconhecimento da técnica SRC com <i>Fast Recursive</i> PCA com classificador SVM com nível de decomposição LL2	273
Tabela 98 – Taxa de reconhecimento da base ocluída com classificador SVM com nível de decomposição LL1	273
Tabela 99 – Taxa de reconhecimento da técnica <i>Asymmetrical</i> PCA com classificador SVM com nível de decomposição LL1	274
Tabela 100 – Taxa de reconhecimento da técnica <i>Fast Recursive</i> PCA com classificador SVM com nível de decomposição LL1	274
Tabela 101 – Taxa de reconhecimento da técnica Fisherfaces com classificador SVM com nível de decomposição LL1	275
Tabela 102 – Taxa de reconhecimento da técnica <i>Fast Robust</i> PCA com classificador SVM com nível de decomposição LL1	275
Tabela 103 – Taxa de reconhecimento da técnica <i>Gappy</i> PCA com classificador SVM com nível de decomposição LL1	276
Tabela 104 – Taxa de reconhecimento da técnica PCA com classificador SVM com nível de decomposição LL1	276
Tabela 105 – Taxa de reconhecimento da técnica <i>Recursive</i> PCA com classificador SVM com nível de decomposição LL1	277
Tabela 106 – Taxa de reconhecimento da técnica SRC com <i>Fast Recursive</i> PCA com classificador SVM com nível de decomposição LL1	277
Tabela 107 – Taxa de reconhecimento da SRC com grafo de Poisson na base de dados AR com ELM com nível de decomposição LL3	278
Tabela 108 – Taxa de reconhecimento da SRC com grafo Laplaciano na base de dados AR com ELM com nível de decomposição LL3	279
Tabela 109 – Taxa de reconhecimento da técnica SSIMGL na base de dados AR com ELM com nível de decomposição LL3	280
Tabela 110 – Taxa de reconhecimento da similaridade estrutural com Grafo Laplaciano na base de dados Yale com ELM com nível de decomposição LL3	281

Tabela 111 – Taxa de reconhecimento SRC com Grafo de Poisson na base de dados	
AR com ELM com nível de decomposição LL2	282
Tabela 112 – Taxa de reconhecimento da SRC com grafo Laplaciano base de dados	
AR com ELM com nível de decomposição LL2	283
Tabela 113 – Taxa de reconhecimento da técnica SSIMGL na base de dados AR com	
ELM com nível de decomposição LL2	284
Tabela 114 – Taxa de reconhecimento da técnica SRC Grafo com Poisson na base de	
dados AR com ELM com nível de decomposição LL1	285
Tabela 115 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano na base	
de dados AR com ELM com nível de decomposição LL1	286
Tabela 116 – Taxa de reconhecimento da técnica SSIMGL na base de dados AR com	
ELM com nível de decomposição LL1	287
Tabela 117 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com	
classificador KNN com nível de decomposição LL3	288
Tabela 118 – Taxa de reconhecimento da técnica SRC com grafo de Laplace com	
classificador KNN com nível de decomposição LL3	288
Tabela 119 – Taxa de reconhecimento com KNN na base AR com a técnica SSIMGL	
com nível de decomposição LL3	289
Tabela 120 – Taxa de reconhecimento com KNN na base de dados Yale após recons-	
trução com SSIMGL com nível de decomposição LL3	289
Tabela 121 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com	
classificador KNN com nível de decomposição LL2	290
Tabela 123 – Taxa de reconhecimento com KNN na base AR com a técnica SSIMGL	
com nível de decomposição LL2	290
Tabela 122 – Taxa de reconhecimento da técnica SRC com grafo de Laplace com	
classificador KNN com nível de decomposição LL2	291
Tabela 124 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com	
classificador KNN com nível de decomposição LL1	291
Tabela 125 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com	
classificador KNN com nível de decomposição LL1	292
Tabela 126 – Taxa de reconhecimento com KNN na base AR com a técnica SSIMGL	
com nível de decomposição LL1	292

Tabela 127 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador SVM com nível de decomposição LL3	293
Tabela 128 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador SVM com nível de decomposição LL3	294
Tabela 129 – Taxa de reconhecimento da técnica SSIMGL com classificador SVM com nível de decomposição LL3	294
Tabela 130 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador SVM com nível de decomposição LL2	295
Tabela 131 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador SVM com nível de decomposição LL2	295
Tabela 132 – Taxa de reconhecimento da técnica SSIMGL com classificador SVM com nível de decomposição LL2	296
Tabela 133 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador SVM com nível de decomposição LL1	296
Tabela 134 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador SVM com nível de decomposição LL1	297
Tabela 135 – Taxa de reconhecimento da técnica SSIMGL com classificador SVM com nível de decomposição LL1	297

Lista de quadros

Quadro 1 – Abreviações geradas para algumas técnicas baseadas em subespaço .	128
Quadro 2 – Abreviações geradas para as três técnicas baseadas em modelo . . .	158
Quadro 3 – Estudos selecionados	213
Quadro 4 – Técnicas para detecção de oclusão	214
Quadro 5 – Técnicas para reconstrução de faces	215

Lista de abreviaturas e siglas

APCA	<i>Asymmetrical Principal Component Analysis</i>
ASM	<i>Active Shape Model</i>
BMA	<i>Block Matching Algorithm</i>
CNN	<i>Convolutional Neural Network</i>
CST	<i>Color Space Technique</i>
DCT	<i>Discrete Wavelet Transform</i>
DFFS	<i>Distance From face Space</i>
DICW	<i>Dynamic Image to Class Warping</i>
EER	<i>Equal Error Rate</i>
EOH	<i>Exceptional Occlusion Handling</i>
FAR	<i>False Acceptance Rate</i>
FARO	<i>Face Recognition Against Occlusion</i>
FRR	<i>False Recognition Rate</i>
FRPCA	<i>Fast Robust Principal Component Analysis</i>
FWPCA	<i>Fast-Weighted Principal Component Analysis</i>
GMM	<i>Gaussian Mixture Models</i>
GPCA	<i>Gappy Principal Component Analysis</i>
HMM	<i>Hidden Markov Models</i>
IBD	<i>Inpainting for Big Data</i>
ICP	<i>Iterative Closest Point</i>
IFR	<i>Iterative Face Recovery</i>

IKFDA	<i>Incremental Kernel Fisher Discriminant Analysis</i>
KAM	<i>Kernel Associative Memory</i>
KNN	<i>K-Nearest Neighbors</i>
LBP	<i>Local binary patterns</i>
MCC	<i>Matthews correlation coefficient</i>
MLWNN	<i>Multi Library Wavelet Neural Network</i>
PCA	<i>Principal Component Analysis</i>
PIN	<i>Personal Identification Number</i>
PSNR	<i>Peak Signal-to-noise Ratio</i>
RGEF	<i>Reformed Gabor Eigenfaces</i>
RMSE	<i>Root Mean Square Error</i>
ROC	<i>Receiver Operating Characteristic</i>
RPCA	<i>Robust Principal Component Analysis</i>
RS	Revisão Sistemática
SOM	<i>Self Organazing Maps</i>
SRC	<i>Sparse Representation Classification</i>
SRF	<i>System Recognition Faces</i>
SSD	<i>Sum of Square Distance</i>
SSEC	<i>Structured Sparse Error Coding</i>
SSIM	<i>Structural Similarity</i>
TLRC	<i>Trimmed Linear Regression Classification</i>
UOM	<i>Universal Occlusion Model</i>

Lista de símbolos

Γ	Conjunto de imagens de face presentes no treinamento das técnicas de reconstrução.
Θ_i	Vetor contendo a diferença entre a imagem de consulta e a imagem média.
Φ	Espaço de faces.
Φ^{no}	Espaço de faces gerado usando a parte não ocluída.
Φ^P	Pseudo espaço de faces gerado usando a parte ocluída.
Υ	Imagem de consulta (imagem parcialmente ocluída).
β	Autovetores.
β^{no}	Autovetores da parte não ocluída.
∂	Derivada parcial.
μ	Média das imagens de face presentes no conjunto de treinamento.
μ_i	Imagem média dos indivíduos da classe i .
α^{no}	Coefficientes de combinação linear da parte não ocluída.
κ	Coefficiente de multiplicação aplicado as matrizes Laplacianas.

Sumário

1	Introdução	34
1.1	<i>Definição do problema</i>	39
1.2	<i>Hipótese</i>	40
1.3	<i>Motivação</i>	41
1.4	<i>Objetivos</i>	41
1.5	<i>Estrutura do documento</i>	42
2	Biometria	44
2.1	<i>Características biométricas</i>	44
2.2	<i>Sistemas biométricos</i>	45
2.3	<i>Modalidades biométricas</i>	48
2.4	<i>Ambientes controlados versus não controlados</i>	49
3	Reconhecimento facial	50
3.1	<i>Reconhecimento facial em ambientes não controlados</i>	53
3.2	<i>Detecção da face</i>	54
3.2.1	Viola-Jones	55
3.2.2	Skin Tone	58
3.3	<i>Detecção de oclusão</i>	60
3.4	<i>Reconstrução da face ocluída</i>	61
3.5	<i>Técnicas para validação das imagens reconstruídas</i>	62
3.5.1	Relação Sinal Ruído de Pico	62
3.5.2	Similaridade Estrutural	63
3.5.3	Raiz Quadrada do Erro quadrático médio	64
3.6	<i>Análise de desempenho</i>	65
3.6.1	Taxa de falsa aceitação e falsa rejeição	65
3.6.2	Matriz de confusão	67
4	Técnicas para detecção e reconstrução de oclusões parciais . .	70
4.1	<i>Contextualização da literatura</i>	70
4.2	<i>Técnicas para detecção de oclusões parciais</i>	74

4.2.1	Skin Tone	74
4.2.2	Limiarização	74
4.2.3	Algoritmo de correspondência dos blocos	75
4.3	<i>Técnicas de reconstrução baseadas em subespaço</i>	77
4.3.1	Eigenfaces	78
4.3.2	<i>Gappy</i> PCA	82
4.3.3	Asymmetrical PCA	83
4.3.4	<i>Recursive</i> PCA	84
4.3.5	<i>Fast Recursive</i> PCA	86
4.3.6	<i>Fast Robust</i> PCA	87
4.3.7	Fisherfaces	90
4.4	<i>Técnicas de reconstrução baseadas em modelo</i>	92
4.4.1	Representação Esparsa com Grafo de Poisson	92
4.5	<i>Considerações finais do capítulo</i>	98
5	Extração de características e classificação	99
5.1	<i>Transformada Wavelet</i>	99
5.2	<i>K-Vizinhos mais próximos</i>	101
5.3	<i>Máquina de aprendizado extremo</i>	102
5.4	<i>Máquina de vetores suporte</i>	104
5.5	<i>Considerações finais do capítulo</i>	105
6	Abordagem Proposta	106
6.1	<i>Proposta</i>	106
6.2	<i>Proposição de três algoritmos</i>	108
6.2.1	Representação Esparsa com Fast Recursive PCA	108
6.2.2	Representação Esparsa com Grafo Laplaciano	110
6.2.3	Similaridade Estrutural com grafo Laplaciano	113
6.3	<i>Aplicação no meio científico deste trabalho</i>	115
7	Materiais e métodos	116
7.1	<i>Bases de dados</i>	116
7.2	<i>Pré-processamento das imagens</i>	118
7.3	<i>Divisões dos experimentos</i>	119

7.4	<i>Escolha do detector de oclusão</i>	120
7.5	<i>Parâmetros utilizados</i>	123
7.5.1	Parâmetros das técnicas de reconstrução baseadas em subespaço .	123
7.5.2	Parâmetros das técnicas de reconstrução baseadas em modelo . .	124
7.5.3	Configurações do extrator de características	124
7.5.4	Parâmetros dos classificadores	125
7.6	<i>Métricas para análise das técnicas</i>	126
8	Experimentos e análises de resultados	127
8.1	<i>Resultados obtidos usando imagens com oclusão</i>	127
8.2	<i>Resultados obtidos usando técnicas baseadas em subespaço</i>	128
8.2.1	Resultados obtidos para os grupos da base AR	128
8.2.2	Resultados das técnicas baseadas em subespaço nos grupos da base Yale	153
8.3	<i>Resultados das técnicas baseadas em modelo</i>	158
8.3.1	Resultados nos quatro grupos da base AR	158
8.3.2	Resultados nos grupos da base Yale	175
8.4	<i>Comparação das melhores técnicas</i>	177
8.5	<i>Teste estatístico de Wilcoxon</i>	180
8.6	<i>Resumo dos experimentos</i>	182
8.7	<i>Prós e contras das técnicas</i>	183
8.7.1	Técnicas baseadas em subespaço	183
8.7.2	Técnicas baseadas em modelo	184
8.8	<i>Limitações de algumas técnicas</i>	184
8.8.1	<i>Asymmetrical PCA</i>	187
8.8.2	<i>Fast Robust PCA</i>	188
8.8.3	Fisherfaces	188
8.8.4	<i>Gappy PCA</i>	189
8.8.5	Representação Esparsa	189
8.9	<i>Considerações finais do capítulo</i>	189
9	Conclusão e perspectivas futuras	192
9.1	<i>Limitações</i>	193

9.2	<i>Perspectivas futuras</i>	193
9.3	<i>Publicações vinculadas a dissertação</i>	194
	Referências¹	196

**Apêndice A – Protocolo de revisão sistemática sobre técnicas
para detecção e reconstrução de oclusões parciais em imagens de face** 206

A.1	<i>Objetivo</i>	206
A.2	<i>Questões de pesquisa</i>	206
A.3	<i>Seleção de fontes</i>	206
A.4	<i>Palavras-Chave</i>	207
A.5	<i>CrITÉRIOS de inclusão</i>	207
A.6	<i>CrITÉRIOS de exclusão</i>	207
A.7	<i>Estratégia de seleção dos dados</i>	208
A.8	<i>Síntese dos dados extraídos</i>	208
A.9	<i>Ameaças a validade</i>	209
A.10	<i>CrITÉRIOS de qualidade</i>	209

Apêndice B – Condução da revisão 210

Apêndice C – Contextualização da literatura 211

C.1	<i>Escopo dos estudos</i>	211
C.2	<i>Bases de dados</i>	211
C.3	<i>Técnicas encontradas na literatura</i>	213
C.3.1	Técnicas para detecção de oclusões parciais	214
C.3.2	Técnicas para reconstrução de imagens de Faces	214
C.4	<i>Considerações finais do apêndice</i>	215

Apêndice D – Matrizes de confusão 216

D.1	<i>Técnicas baseadas em subespaço</i>	216
D.2	<i>Técnicas baseadas em modelo</i>	220

Apêndice E – Tabelas de resultados 222

¹ De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023.

<i>E.1</i>	<i>Resultados de reconstrução com técnicas baseadas em subespaço . . .</i>	222
E.1.1	Resultados com ELM	222
E.1.2	Resultados com KNN	250
E.1.3	Resultados com SVM	264
<i>E.2</i>	<i>Resultados de reconstrução com técnicas baseadas em modelo</i>	278
E.2.1	Resultados com ELM	278
E.2.2	Resultados com KNN	289
E.2.3	Resultados com SVM	293

1 Introdução

Com a crescente ênfase na segurança nacional e global, há uma necessidade crescente e urgente de identificação humana. De acordo com Jafri e Arabnia (2009), as estratégias tradicionais de reconhecimento de identidade tais como números PIN, *tokens*, senhas e cartões de identificação tornaram-se obsoletas. Esses métodos de segurança tradicionais estão sendo facilmente fraudados, trazendo preocupações no que diz respeito à sua facilidade de aquisição e utilização por parte de terceiros não-autorizados. Senhas e PINs podem ser esquecidos, roubados ou até mesmo descobertos por pessoas mal-intencionadas, e cartões, *tokens*, chaves e similares podem ser perdidos, esquecidos ou clonados (LUMINI; NANNI, 2017).

De modo a superar essas dificuldades algumas abordagens vêm sendo propostas na literatura visando oferecer identificação automática, precisa e confiável. Dentre essas abordagens destaca-se a biometria que segundo Hassaballah e Aly (2015) é uma área que abrange uma diversidade de tecnologias utilizadas para fins de identificação pessoal por meio da mensuração e análise dos vários aspectos físicos e comportamentais de cada indivíduo. As características físicas estão relacionadas com a forma do corpo, incluindo a face, íris, retina, impressão digital, palma da mão, veia do dorso da mão, geometria da mão, lóbulo da orelha, etc. Enquanto as características comportamentais estão relacionadas com o padrão de comportamento de uma pessoa, tais como marcha, assinatura, dinâmica de digitação, voz, etc. De acordo com Filipe (2010), a biometria surge como forma de superar as novas necessidades e desafios, proporcionando maiores níveis de segurança, visto que os traços biológicos não podem ser forjados, furtados, extraviados e esquecidos como ocorre com os métodos de segurança tradicionais.

A biometria vem alcançando muito sucesso por utilizar características físicas e/ou comportamentais de cada indivíduo como método de identificação. De acordo com Finizola et al. (2018), a biometria possui finalidades que buscam aprimorar ou até mesmo suceder os métodos tradicionais de segurança. Segundo Sajjad et al. (2018), a área biométrica está chegando a tal patamar de segurança por utilizar características que satisfazem quatro requisitos básicos: universalidade – todas as pessoas devem possuir essa característica; distinção – duas pessoas devem possuir características distintas; permanência

- a característica deve ser invariante durante um determinado período de tempo; mensurável
- é necessário que a característica possa ser medida quantitativamente.

De acordo com Lumini e Nanni (2017), Oloyede, Hancke e Kapileswar (2017) a face é a modalidade biométrica mais comumente vista e usada em nossa vida diariamente. É uma característica universal, única para cada pessoa e possui boa aceitabilidade em ambientes de captura. Por isso, inúmeros órgãos sejam eles governamentais ou instituições privadas estão mantendo bancos de dados de fotografias de pessoas contendo a face, objetivando identificação do indivíduo.

Comparada com outras modalidades biométricas tais como impressão digital e íris, a face provê um método de identificação direto, amigável e conveniente (SHERMINA; VASUDEVAN, 2012). Além disso, possui várias vantagens, conforme descrito abaixo, que a tornam uma das modalidades biométricas mais preferidas para identificação humana:

- Natureza biológica: A face é uma característica biométrica muito utilizada pelos seres humanos no reconhecimento de pessoas, o que a torna provavelmente a modalidade biométrica mais comum para fins de identificação ou autenticação. Por exemplo, no controle de acesso, é fácil para os administradores rastrear e analisar a pessoa autorizada a partir dos dados de face após a sua autenticação. A ajuda de usuários comuns (por exemplo, administradores) pode melhorar a confiança e a aplicabilidade dos sistemas de reconhecimento, ao passo que os sistemas de reconhecimento baseado em impressões digitais ou íris requerem um especialista com habilidades profissionais para fornecer uma confirmação confiável.
- Não intrusiva: ao contrário de impressões digitais e íris, as imagens de face podem ser facilmente adquiridas à distância sem contato físico. As pessoas se sentem mais confortáveis para usar a face como identificador em sua vida diária. Um sistema de reconhecimento facial pode coletar dados biométricos de uma maneira rápida e que é facilmente aceito pelo público.
- Menos cooperação: em comparação com a íris e a impressão digital, o reconhecimento facial tem uma menor exigência de cooperação entre os sujeitos. Em algumas aplicações particulares, como vigilância, um sistema de reconhecimento facial pode identificar uma pessoa sem participação ativa dos sujeitos.

Nessa área existe um progresso significativo em reconhecimento automático de face em condições controladas (MIN; HADID; DUGELAY, 2014). Entretanto, o desempenho

em condições não controladas é ainda insatisfatório (WEI et al., 2014). Sistemas de reconhecimento facial em ambientes de mundo real, frequentemente, lidam com condições não controladas e não previsíveis tais como grande mudança na iluminação, pose, expressão e oclusão, as quais introduzem variações intraclasse e degradam a performance do reconhecimento. Segundo Oloyede, Hancke e Kapileswar (2017), Tajima et al. (2013), Min, Hadid e Dugelay (2014) o problema relacionado a oclusão é relativamente pouco estudado na área quando comparado a problemas relacionados a variações de pose, iluminação e expressão. Algumas dessas dificuldades encontradas ao lidar com oclusões em imagens de face em ambientes não controlados podem ser encontradas no trabalho de Ghiasi e Fowlkes (2014).

Embora tenha sido dada pouca atenção ao problema de oclusão na literatura de reconhecimento facial, a importância deste problema deve ser enfatizada, pois a presença de oclusão é muito comum em cenários não controlados e pode estar associada a várias questões de segurança. Do ponto de vista do usuário, as oclusões faciais podem ocorrer por várias razões, sendo elas intencionais ou não. Em primeiro lugar, acessórios faciais como óculos de sol, cachecol, maquiagem facial, chapéu e boné são bastante comuns na vida diária. Outras pessoas também usam véus por convicções religiosas ou hábitos culturais (MIN; HADID; DUGELAY, 2014).

Por outro lado, a oclusão também está aparecendo em cenários de segurança e saúde. Por exemplo, a máscara cirúrgica utilizada obrigatoriamente em áreas restritas de hospitais, como também é frequentemente usada por pessoas na Ásia Oriental (por exemplo, China, Japão) para evitar a exposição a poluição do ar, doenças respiratórias ou alergia ao pólen. Paralelamente nas áreas de construção, existe o capacete de segurança atuando como um instrumento vital, de forma a garantir a segurança das pessoas em tais áreas (DU; SHEHATA; BADAWY, 2011).

Dessa forma, identificar as pessoas sem qualquer cooperação de remoção de oclusão devido a acessórios faciais traz grande conveniência e conforto para os usuários em inúmeros cenários. Por outro lado, identificar a presença de oclusões em locais restritos (por exemplo, hospital, área de construção) e revelar a identidade das pessoas nessas áreas garantem a segurança no ambiente. Da mesma forma, a detecção da presença de oclusão pode identificar pessoas suspeitas em certas áreas (por exemplo, estádios de futebol, estações de metrô, caixas eletrônicos, lojas, aeroportos e etc.) e o reconhecimento facial (apesar da

presença de oclusão) nessas áreas pode ajudar a polícia a encontrar criminosos/fugitivos. Em outro ângulo os vândalos e os ladrões de caixas eletrônicos tendem a usar cachecóis e / ou óculos de sol de maneira a impedir que suas faces sejam reconhecidas. Ladrões de bancos e lojas geralmente usam boné ao entrar em lugares em que cometem ações ilegais (ZHANG et al., 2016). A Figura 1 ilustra alguns tipos de oclusão, sendo elas oclusões normais e oclusões intencionais. Em suma, o reconhecimento robusto de face ocluídas parcialmente é muito importante e tem muitos usos potenciais no mundo da vigilância.

Figura 1 – Ilustração de diferentes tipos de oclusões parciais: (a) oclusões faciais comuns em nossa rotina diária; (b) oclusões faciais relacionadas a questões de segurança

Fonte: Jonas Mendonça Targino, 2019

Tratar com detecção e reconstrução de oclusões parciais em imagens de face não é uma tarefa trivial, uma vez que a localização, tamanho e forma das oclusões são desconhecidas. Atualmente, a maioria dos detectores de oclusão são treinados em faces com tipos específicos de oclusões apresentando queda de performance quando apresentados aos mais variados tipos de oclusões presentes em ambientes reais. Por exemplo, as variações de pose podem ser reduzidas usando imagens de face com múltiplas vistas de poses ou modelo de face em 3D. Por outro lado, um tipo específico de oclusão (por exemplo, óculos de sol) não pode ser produzida por outros tipos de oclusões (por exemplo, lenço). Logo, faz-se necessário avaliar o impacto das técnicas de detecção e reconstrução sobre diferentes tipos de oclusão para o reconhecimento biométrico visando identificar os principais prós e contras dessas técnicas como também eventuais limitações.

Há três categorias principais de abordagens empregadas para atacar o problema de reconhecimento facial na presença da oclusão: *i)* abordagens baseadas em reconstrução, que formulam o reconhecimento de faces ocluídas como um problema de reconstrução. Uma face ocluída é reconstruída por meio de uma combinação linear das imagens de

face de treinamento. Em seguida a imagem reconstruída é atribuída para a classe que possui menor erro de reconstrução. *ii*) Abordagens baseadas em correspondência local, as quais extraem características locais da face, tais que as partes afetadas e não afetadas da face possam ser analisadas separadamente. *iii*) Abordagens baseadas em características insensíveis, as quais extraem características da face que são robustas a oclusão, tais como, segmentos lineares, diferença da orientação do gradiente, diferença da fase da função Gabor.

Um problema comum dos métodos baseados em reconstrução, é que estes usualmente requerem um número grande de exemplos por indivíduo para representar uma imagem de teste. Muitos métodos baseados em reconstrução assumem que as imagens do treinamento são capturadas em condições controladas. Entretanto, esta suposição geralmente não acontece em cenários de mundo real. Outro problema relacionado com esta categoria é que esta pode incorrer em um alto custo computacional. A ideia por trás das abordagens baseadas em correspondência local é que as alterações da aparência facial causadas por oclusões são de natureza local. Somente partes de uma face são distorcidas por oclusões, enquanto outras são menos afetadas e podem ser usadas para o reconhecimento. Portanto, em comparação com os métodos baseados em reconstrução, os métodos baseados em correspondência local são menos propensos a atacar a situação em que mais de metade da face esteja ocluída. Por outro lado, as abordagens baseadas em características insensíveis assumem que as características extraídas localmente são menos prováveis de serem afetadas pela oclusão. No entanto, as formas das oclusões em cenários de mundo real são imprevisíveis, logo é difícil encontrar uma representação conveniente que seja insensível a vários tipos de oclusão. Esta dissertação irá focar em métodos baseados em reconstrução.

No caso das abordagens baseadas em reconstrução, há dois problemas distintos relacionados com o reconhecimento facial com oclusões: detecção da face ocluída e a recuperação da face ocluída. A primeira tarefa consiste em determinar se uma imagem de face está ou não ocluída, e pode ser utilizada para rejeitar automaticamente as imagens ocluídas em aplicações, tais como imagens de face para passaporte. Este mecanismo de rejeição nem sempre é adequado para reconhecimento facial em alguns cenários (por exemplo, vigilância), onde nenhuma outra imagem pode ser obtida devido à falta de cooperação do indivíduo. A segunda tarefa consiste em restaurar as regiões ocluídas

das imagens faciais. Esta tarefa pode recuperar as áreas obstruídas, mas esta pode não contribuir diretamente para o reconhecimento, já que as informações da identidade do indivíduo podem estar contaminadas por algum ruído durante a recuperação.

As técnicas empregadas para reconstrução podem ser subdivididas em baseadas em subespaço e baseadas em modelo. Existem várias técnicas propostas na literatura para detecção e reconstrução de oclusão em imagens de face. No entanto, não há nenhum estudo que mencione quais técnicas são mais adequadas para determinado tipo de oclusão. Nesse sentido o diferencial dessa pesquisa consiste em realizar um estudo comparativo das técnicas para detecção e reconstrução de faces parcialmente ocluídas, de modo que pretende-se avaliar o impacto dessas técnicas na detecção e reconstrução de diferentes tipos de oclusões em imagens de face visando o reconhecimento biométrico. Como resultado deste estudo, foi possível identificar os principais prós e contras dessas técnicas como também eventuais limitações. Visando atacar tais limitações e melhorar o desempenho na reconstrução, três técnicas híbridas, que envolve a combinação de técnicas baseadas em subespaço e modelo, foram propostas nesta dissertação.

A presente proposta apresenta um grau significativo de contribuição em termos gerais, abrangendo o estado de arte, suas técnicas, algoritmos para detecção e reconstrução de oclusão, combinação de técnicas e condições de viabilidade de aplicação, levando em conta as variações de iluminação, pose e oclusão. Os resultados obtidos com esta pesquisa serão de grande valia para pesquisadores que estão trabalhando na área, como também iniciantes que almejam conhecimento holístico do estado de arte para desenvolvimento de futuras pesquisas, de modo a produzir um conhecimento e enriquecimento para a área de biometria e para os pesquisadores que tentam colaborar no reconhecimento facial independente das condições de coleta de dados.

1.1 Definição do problema

No ramo biométrico, manipular oclusões de objetos ou faces é uma tarefa difícil quando necessitamos realizar o reconhecimento de uma pessoa em um ambiente irrestrito. No estado de arte existem poucos algoritmos responsáveis por tentar lidar e resolver problemáticas como essa (TARGINO; PERES; LIMA, 2018b).

Essa pequena quantidade de algoritmos ocorre devido às imagens com oclusões serem coletadas em ambientes não colaborativos, em que o usuário não possui a intenção de colaborar expondo sua face frente a uma câmera, além do mais o ambiente não é de certa forma propício para o processo de coleta de dados. A partir disso surge esse problema na biometria, em que esta, deve tentar se adaptar ao contexto e gerar novos métodos que não sejam intrusivos para a coleta dos dados, possibilitando o aparecimento de oclusões parciais, as quais o sistema deve tentar tratar, removendo a parte ocluída, reconstruindo a face e logo em seguida identificando o indivíduo.

Mediante problemáticas como essa, surge a necessidade de técnicas responsáveis por manipular a parte ocluída, visto que a oclusão possibilita quantidades insuficientes e ruidosas de características, resultando em baixas performances alcançadas pelos classificadores.

Os algoritmos existentes na literatura possuem índice de detecção e reconstrução de oclusão não tão consideráveis, quando comparados aos algoritmos que lidam com a mesma problemática em ambientes controlados. Com isso, o reconhecimento em ambientes com variações de suas condições sejam elas: iluminação, expressão, oclusão e pose, são oportunos a redução da taxa de reconhecimento.

Conforme já mencionado, o reconhecimento facial baseado em faces não ocluídas ainda não apresenta resultados satisfatórios, devido à dificuldade de extração das características essenciais para a identificação do indivíduo. Apresentando uma pequena quantidade de algoritmos na área com tal iniciativa de pesquisa, configurando baixo desenvolvimento nessa área. É interessante perceber que muitos desses algoritmos para detecção de oclusões parciais são específicos para determinado tipo de oclusão, ou ambiente, não existindo uma técnica que se apresente ideal para todos os tipos de oclusões e ambientes.

1.2 Hipótese

A realização de um estudo comparativo envolvendo técnicas presentes na literatura para detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico servirá como um artefato de consulta para pesquisadores da área, possibilitando uma visão holística das principais técnicas de detecção e reconstrução existentes na literatura como também seus eventuais cenários de vantagens e desvantagens.

1.3 *Motivação*

Durante a etapa de reconhecimento a existência de oclusões parciais em imagens de face promovem a queda de performance da estratégia de classificação, visto que existe a ausência de características na imagem da face. Essa redução de performance impacta diretamente no número de trabalhos presentes na literatura que tratam de ambientes não controlados, corroborando para um menor número de trabalhos dispostos no meio científico. Além dos trabalhos presentes na literatura com fins de detecção e reconstrução de oclusões parciais não explicitarem de maneira clara como o experimento foi realizado, não utilizam uma nomenclatura matemática uniforme e geralmente não disponibilizam o código ou pseudocódigo.

Essa falta de informações um pouco mais detalhadas nos artigos aumenta significativamente a dificuldade de replicação da técnica por outras pessoas ou grupos de pesquisa. Desse modo, torna-se interessante a realização de um estudo comparativo envolvendo técnicas para detecção e reconstrução de oclusões parciais de imagens de face obtidas por meio de bases de dados conhecidas pela comunidade científica e dispostas publicamente, fornecendo com isso um artefato de consulta contendo os prós e contras de cada técnica, seus respectivos códigos, como também uma notação matemática uniforme. Com base neste estudo, foi possível propor três técnicas híbridas, que envolvem a combinação de técnicas baseadas em subespaço e modelo

1.4 *Objetivos*

O objetivo principal deste trabalho foi investigar, implementar, combinar e comparar diferentes técnicas para detecção e reconstrução de oclusões parciais em imagens de face humanas visando identificação biométrica em ambientes não controlados com usuários não colaborativos. As técnicas de detecção e reconstrução foram avaliadas em termos da taxa de reconhecimento usando diferentes classificadores (K-vizinhos mais próximos, Máquina de Aprendizado Extremo e Máquinas de Vetores Suporte). Teste de significância estatística foi realizado para identificar as melhores e piores técnicas para determinado tipo de oclusão. Visando alcançar os objetivos principais, foram adotados os seguintes objetivos secundários:

- revisão sistemática da literatura buscando encontrar as técnicas para detecção e reconstrução de oclusões parciais em imagens de face presentes na literatura;
- implementação das principais técnicas de detecção e reconstrução de imagens de face ocluídas;
- proposição de novas (ou variações) técnicas de detecção e reconstrução de imagens de face ocluídas;
- emprego das técnicas de detecção e reconstrução de imagens de face ocluídas para reconhecimento biométrico;
- análise comparativa dos resultados obtidos;
- publicação dos resultados para que possam ser utilizados pela comunidade científica em trabalhos futuros.

1.5 *Estrutura do documento*

Os capítulos desta dissertação descrevem a teoria necessária para compreensão dos objetivos desta dissertação. Incluindo-se a introdução, os demais capítulos estão organizados da seguinte forma:

- O Capítulo 2 apresenta uma fundamentação teórica sobre biometria, sistemas biométricos e tipos de ambientes de coleta de dados que servirão como base para o entendimento do corpo dessa dissertação.
- No Capítulo 3 são abordados alguns conceitos fundamentais sobre a modalidade biométrica de face, seus prós e contras, tipos de ambientes e técnicas de detecção da região facial.
- O Capítulo 4 detalha as técnicas presentes na literatura para detecção e reconstrução de oclusões parciais em imagens de face que foram implementadas neste trabalho.
- No Capítulo 5 são apresentadas as técnicas para extração das características e classificação utilizadas nesse trabalho.
- O Capítulo 6 descreve a proposta de pesquisa, como também seus objetivos. Além de apresentar as três técnicas para reconstrução de faces propostas durante o desenvolvimento deste estudo comparativo;

- Enquanto no capítulo 7 apresenta-se descrições a respeito das bases de dados utilizadas, formas de pré- processamento das imagens, estratégias de extração das características, classificadores utilizados e métricas utilizadas.
- No Capítulo 8 apresenta-se a sumarização dos resultados obtidos nas duas bases de dados, abordando também os cenários de vantagens e desvantagens de cada técnica.
- Enquanto no Capítulo 9 são apresentados os comentários gerais deste trabalho, como também perspectivas futuras.
- No Apêndice A é apresentado o método de elaboração da Revisão Sistemática (RS) efetuada juntamente com este trabalho.
- No Apêndice B é descrita a estratégia de condução dos artigos advindos da RS.
- Paralelamente no Apêndice C é realizada uma breve contextualização da literatura de técnicas para detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico.
- Enquanto no Apêndice D são apresentadas as matrizes de confusão de cada técnica de reconstrução sobre os quatro grupos de oclusões naturais da base AR.
- Por último e não menos importante no Apêndice E são apresentadas todas as tabelas de resultados de acurácia de cada técnica por classificador e nível de decomposição utilizado. Dessa forma, possibilitando eventuais consultas conforme a necessidade.

2 Biometria

Este capítulo apresenta os conceitos fundamentais de biometria, algumas modalidades biométricas, com destaque para a face e seus cenários de captura. O objetivo é possibilitar um maior embasamento teórico para compreensão da pesquisa desenvolvida. Paralelamente apresenta-se os ambientes controlados e não controlados como também suas vantagens e eventuais desvantagens.

2.1 *Características biométricas*

O emprego de características biométricas para identificação de pessoas começou em meados do século XIX. Segundo Costa (2011), o departamento de polícia de Paris foi o primeiro a utilizar a medição dos corpos para identificação de criminosos. Pouco tempo depois descobriu-se que a impressão digital fornece características capazes de identificar um indivíduo (JAIN; ROSS; PRABHAKAR, 2004). A partir desse marco temporal do surgimento da biometria, emergiram inúmeras iniciativas de modalidades biométricas.

A biometria surge perante a sociedade atual como uma alternativa aos métodos de segurança tradicionais (SHARIF; MOHSIN; JAVED, 2012), os quais são propícios a fraudes e roubos. Mediante justificativas como esta, inúmeros órgãos públicos e privados vêm implantando medidas preventivas de segurança. Um destes órgãos é a polícia, que vem utilizando impressões digitais há décadas. A biometria é aplicada em inúmeras áreas, as quais podemos dividir em três grupos principais, a saber:

- Comercial, com o intuito de promover, por exemplo, segurança nos cartões de crédito e restrição de acesso aos dispositivos móveis.
- Governamental, cujo interesse é estabelecer normas de segurança em ambientes públicos visando favorecer toda a população.
- Forense, tem como finalidade estratégias criminais, como por exemplo identificação de atitudes terroristas.

2.2 Sistemas biométricos

Segundo Delac e Grgic (2004) um sistema biométrico é composto por um conjunto de módulos, conforme a Figura 2, a saber:

- módulo Sensorial: módulo responsável por fazer a coleta da característica biométrica;
- módulo de Extração das características: responsável por extrair as características que serão utilizadas para a construção do vetor de características;
- módulo de Comparação: módulo responsável por realizar a comparação do vetor de características construído com os padrões armazenados na base de dados;
- módulo de Decisão: responsável por verificar o retorno do módulo de comparação e decidir se o usuário com aquelas características é aceito ou não;
- base de Dados: realiza o armazenamento de todos os padrões de usuários que irão fazer uso do sistema e disponibiliza essas informações para o módulo de comparação.

Figura 2 – Módulos de um sistema biométrico

Fonte: Jonas Mendonça Targino, 2019

A área de reconhecimento biométrico teve grandes avanços significativos em termos de confiabilidade e precisão. Segundo Lone, Zakariya e Ali (2011), algumas modalidades biométricas têm alcançado um bom desempenho em aplicações práticas. Dentre as principais modalidades temos: impressão digital, face (SHARIF; MOHSIN; JAVED, 2012; SHERMINA; VASUDEVAN, 2012), voz, palma da mão e íris.

Um fato importante atrelado a biometria é que nem toda característica física ou comportamental é uma modalidade biométrica, Jain, Ross e Prabhakar (2004) afirma que alguns requisitos devem ser satisfeitos, os quais são listados logo abaixo:

- universalidade: cada pessoa deve possuir essa característica;
- distinção: duas pessoas devem possuir características distintas;

- **permanência:** a característica deve ser suficientemente constante (no que diz respeito ao critério de correspondência) durante um determinado período de tempo;
- **mensurabilidade:** deve ser possível medi-la.

Para o reconhecimento de uma pessoa é necessário o armazenamento prévio das suas características biométricas. Essa fase chamada de cadastramento é anterior a fase de reconhecimento. Na etapa de reconhecimento existem dois modos: a identificação e a verificação, estas duas modalidades apresentam algumas diferenças no método envolvido, devido à natureza diferente. Abaixo é apresentada uma descrição detalhada de cada uma.

- **Identificação** - é uma etapa em que o usuário fornece suas características para o sistema, e este realiza uma comparação com todos os *templates* da base de dados (comparação 1:N). Neste caso, o sistema é responsável pela tarefa de comparar e analisar qual a pessoa da base de dados possui aquelas características. De forma resumida, as características extraídas da imagem de consulta serão comparadas com todos os vetores de características armazenados, e uma decisão será tomada de modo a identificar a classe à qual o vetor de características de entrada pertence. A vantagem da identificação é que esta elimina a necessidade de uso de senhas ou cartões. A Figura 3 ilustra o conceito de identificação, em que se tem uma imagem de entrada a qual é comparada com as n imagens presente na base.

Figura 3 – Processo de identificação facial

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

- **Verificação** - comumente chamada de autenticação, pode ser considerada um subconjunto da tarefa de reconhecimento. A etapa de verificação envolve uma

comparação um para um, entre as características extraídas da imagem de consulta e as características da imagem (ou classe) que o usuário afirma ser. Neste caso, o sistema recebe como entrada um vetor de característica e uma senha, este verifica se o usuário é a pessoa que alega ser. Em outras palavras, caso uma pessoa se posicionar na frente de um sistema autenticação, e alegar ser uma determinada pessoa, o sistema irá analisar apenas se ela é aquele usuário que alega ser, ou não. A Figura 4 ilustra um exemplo de comparação utilizando o processo de verificação.

Figura 4 – Verificação facial

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

A Figura 5 ilustra uma comparação entre o processo de verificação e identificação, sendo possível perceber que na fase de verificação é retornado apenas 1 indivíduo (o qual o usuário afirma ser), já na fase de identificação são retornados todos os n indivíduos presentes na base de dados.

Figura 5 – Exemplo do processo de verificação e identificação

Fonte: Jonas Mendonça Targino, 2019

2.3 Modalidades biométricas

Inúmeros trabalhos utilizam como estratégia de reconhecimento biométrico a face, íris, impressão digital, palma de mão e forma de andar. Dentre estes podemos destacar os trabalhos propostos por Galdi, Nappi e Dugelay (2016) e Costa (2011). O primeiro emprega a imagem da íris e características do dispositivo de captura (sensor) utilizado pelo usuário para realizar a autenticação biométrica via *smartphone*. Já o segundo investiga diversas formas de fusão de íris e face com fins biométricos, demonstrando que a fusão de características biométricas pode melhorar o desempenho do reconhecimento.

Já no contexto de impressão digital, o trabalho de Duru, Targino e Lima (2018) apresenta um estudo comparativo envolvendo técnicas tradicionais de classificação para analisar imagens de impressões digitais coletadas mediante cinco sensores. Tal trabalho visou investigar a influência do sensor de captura e da técnica de extração de característica no reconhecimento biométrico. Sobre outra perspectiva o trabalho de Benaliouche e Touahria (2014) realizou a fusão de impressão digital e íris tentando obter melhores resultados de reconhecimento.

Por outro lado, os trabalhos de Kumar e Kathiresan (2017) e George et al. (2017) utilizam a forma de andar como modalidade biométrica. Ambos atingiram resultados consideráveis em termos de acurácia. O primeiro utilizou Máquina de Vetores Suporte (do inglês: *Support Vector Machines* - SVM) e Redes Neurais *Multi Layer Perceptron* - *MLP* como classificadores. Já o segundo, utilizou apenas a Redes Neurais MLP como estratégia de classificação. Logo a seguir com o auxílio da Figura 6 é possível visualizar oito exemplos de modalidades biométricas.

Figura 6 – Exemplos de algumas modalidades biométricas

Fonte: Jonas Mendonça Targino, 2019

2.4 Ambientes controlados versus não controlados

Ambientes controlados são ambientes com condições propícias para a coleta de dados, projetados com esta finalidade. Já ambientes não controlados correspondem aos mais variados espaços, os quais podem fornecer uma coleta de dados com amostras ruidosas, as quais implicam em maiores dificuldades de identificação do indivíduo. Considerando o contexto de reconhecimento biométrico facial, ambientes controlados são locais com condições adequadas de iluminação, baixa complexidade de fundo da imagem, pequena variação do ângulo de visualização da câmera (geralmente em ambientes internos) e total colaboração do usuário junto ao sensor de coleta, de modo a evitar viés frente a captura da imagem a fim de minimizar seus efeitos na taxa de identificação do sistema.

Também se encontra presente na biometria facial os ambientes não controlados, os quais contém câmeras de vídeo-vigilância que podem ser utilizadas para garantir o monitoramento e a segurança dos usuários que ali frequentam. As quais, podem servir para identificar as pessoas presentes naquele determinado local (geralmente ambientes externos). Uma característica importante desses ambientes é que todos usuários estão cientes que sua imagem está sendo capturada. Em ambientes como este, o usuário não possui a menor intenção de colaborar frente a coleta de dados, como também não existe nenhuma preocupação em realizar um processo sistemático para a coleta de informações dos usuários presentes naquele local.

3 Reconhecimento facial

A face é a modalidade biométrica mais utilizada (XIE; ZISSERMAN, 2018), visto que apresenta várias vantagens perante as outras modalidades, tais como, características naturais, método de coleta não intrusivo e fácil manipulação. Segundo Lone, Zakariya e Ali (2011) essa modalidade de reconhecimento está aumentando gradativamente seu prestígio frente a segurança pessoal nas últimas décadas, conseguindo obter resultados consideráveis de confiança. Com todas essas vantagens essa modalidade biométrica vem possibilitando avanços em pesquisas biométricas com iniciativas que visam aumento de sua credibilidade e precisão no reconhecimento de pessoas.

Desde o advento da fotografia, inúmeros órgãos públicos e privados têm mantido bancos de dados de fotografias de pessoas contendo a face (por exemplo, para identificação pessoal, passaportes, cartões de associação, controle de acesso a computadores ou equipamentos, autenticação bancária, operações financeiras e utilização nos sistemas de vigilância). O interesse pelo reconhecimento automático de face está em alta devido as suas inúmeras aplicações no cotidiano, incluindo o controle de acesso e sistemas de segurança (BUCIU, 2014).

O problema de reconhecimento facial a partir de uma ou mais imagens de faces foi abordado na década de 60 por pesquisadores de visão computacional. Desde então pesquisadores têm apresentado interesse e motivações no desenvolvimento de sistemas que possibilitem maior confiabilidade em aplicações de mundo real. De acordo com Lumini e Nanni (2017) por meio da face podemos realizar análises das características faciais e identificar momentaneamente as pessoas, seu estado emocional e sua expressão facial. O reconhecimento biométrico da face é realizado a partir de técnicas de processamento de imagens da face do indivíduo capturadas por uma ou mais câmeras.

Enquanto os primeiros sistemas de reconhecimento facial eram baseados em características geométricas (distâncias entre pontos de referência pré-definidos), a abordagem de Eigenface popularizada por Turk e Pentland em 1991 (TURK; PENTLAND, 1991) era baseada na aparência facial holística. Técnicas baseadas em aparência holística geram uma representação compacta de toda a região da face na imagem adquirida mapeando a imagem de alta dimensionalidade em um subespaço de baixa dimensionalidade. Esse subespaço é definido por um conjunto de vetores de base representativos, que são aprendidos usando

um conjunto de imagens de treinamento. O método de análise de características locais de Penev e Atick (PENEV; ATICK, 1996) e o método de Fisherface de Belhumeur et al (BELHUMEUR; HESPANHA; KRIEGMAN, 1997) são outros exemplos de reconhecimento facial baseado em aparência holística.

A abordagem de correspondência de grafos elásticos de Wiskott et al. (WISKOTT et al., 1997) foi um trabalho pioneiro no reconhecimento facial baseado em modelo. As técnicas baseadas em modelo tentam derivar uma representação independente de pose das imagens faciais construindo modelos faciais 2D ou 3D. Estes esquemas requerem tipicamente a detecção de vários pontos fiduciais ou de referência na face (por exemplo, cantos dos olhos, ponta do nariz, cantos da boca e queixo), o que leva a um aumento de complexidade em comparação com técnicas baseadas na aparência. O modelo proposto por Blanz e Vetter (BLANZ; VETTER, 2003) avançou no uso de modelos 3D no reconhecimento facial, explorando tanto a textura facial quanto as características da forma.

Como os esquemas baseados em aparência usam os valores brutos de intensidade de pixel, os quais se tornam sensíveis às mudanças na iluminação ambiente e nas expressões faciais. Mediante essa sensibilidade na variação da iluminação algumas técnicas são dispostas na literatura, algumas dessas técnicas são Transformada de Características Invariante a Escala (do inglês: *Scale Invariant Feature Transform* - SIFT) (LOWE, 2004) e Padrão Binário Local (do inglês: *Local Binary Patterns* - LBP) (OJALA; PIETIKAINEN; MAENPAA, 2002). Essas técnicas utilizam representações mais robustas que caracterizam a textura de uma imagem usando a distribuição de valores de pixel locais. Codificação de representação esparsa (WRIGHT et al., 2009a) e reconhecimento de face baseado em aprendizagem profunda (TAIGMAN et al., 2014) são alguns dos avanços mais notáveis na área do reconhecimento facial na última década.

A tarefa de reconhecimento pode ser considerada uma atividade simples quando falamos em reconhecimento por um ser humano. Como sabemos o cérebro humano pode identificar corretamente uma pessoa a partir de sua imagem facial, mesmo sob as mais variadas condições do ambiente, como variações de iluminação, pose, oclusão e expressão facial, observando apenas uma de suas características ou partes dessas, e até mesmo com distorções ou deformações. Entretanto, essa atividade apresenta-se extremamente complexa ao ser implementada em um computador. Um sistema de reconhecimento facial é considerado adequado quando detecta de forma automática uma face presente na imagem

adquirida e identifica a face mediante qualquer ponto de vista, independente da variação de pose, iluminação, etc.

É possível visualizar na Figura 7 o processo necessário para identificação de uma face sem oclusão e uma face ocluída parcialmente. De maneira que podemos perceber a adição de mais quatro fases no processo de reconhecimento tradicional, adicionando um pouco mais de complexidade a tarefa de reconhecimento.

Figura 7 – Etapas necessárias para o reconhecimento de uma face sem oclusão e com oclusão

Fonte: Jonas Mendonça Targino, 2019

As principais abordagens que visam o reconhecimento facial são baseadas na localização e forma dos atributos faciais também conhecidos como pontos-chave, tais como, os olhos, sobrancelhas, nariz, boca e queixo, e suas relações espaciais. Essas abordagens tomam por base uma análise global da imagem da face como uma combinação de outras partes daquela mesma face. Após a localização da face algumas características são extraídas da mesma analisando sua geometria facial, dentre estas características temos a análise da distância entre os pontos-chave, tais como distância entre boca e nariz, olho e nariz, queixo e olhos, etc.

Há várias aplicações que usam o reconhecimento facial como método de segurança, dentre as quais temos:

- sistemas de vigilância e monitoramento fechado de circuito televisionado;
- investigações de imagens;
- reconstrução de imagens;
- identificação de criminosos;

- autorização de acesso.

A face como as outras modalidades biométricas possui vantagens e desvantagens, a saber:

Vantagens:

- nenhuma necessidade de contato;
- sensores comumente usados e disponíveis (câmeras de segurança);
- grandes quantidades de dados existentes, permitindo avaliação a partir de imagens armazenadas em *backup*;

Desvantagens:

- a face pode ser obstruída por oclusões, como também outras variações (iluminação, expressão e pose);
- mudança da face de acordo com o tempo;
- possibilidade de fornecimento de imagens faciais de baixa resolução.

3.1 Reconhecimento facial em ambientes não controlados

A face é a modalidade biométrica com menor grau de intrusão mediante a privacidade dos indivíduos, possibilitando comodidade e bem-estar por parte dos usuários durante o processo de coleta dos dados. Conforme Buciu (2014), o número de sistemas de reconhecimento biométrico que usam a face como modalidade biométrica é relativamente elevado. Entretanto, o desempenho desses sistemas é apenas razoável. Esta afirmativa deve-se ao fato de que as técnicas empregadas apresentam grandes dificuldades para manipular imagens de face coletadas em ambientes não controlados. Essas dificuldades para manipular imagens de face coletadas em ambientes não colaborativos, deve-se às condições do ambiente e a não cooperação por parte do usuário para a coleta dos dados, essa é uma das desvantagens dos ambientes não controlados.

Com o auxílio da Figura 8 podemos visualizar imagens de dois indivíduos (i e ii) contendo alguns tipos de variações (iluminação, expressão, pose, oclusão e oclusão com iluminação) encontradas ao lidarmos com ambientes não controlados.

Figura 8 – Tipos de variações advindas de ambientes semi-controlados

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

As imagens de face coletadas sobre condições não controladas apresentam fortes variações, estas são provindas do ambiente de coleta. A partir dessas variações surge uma lacuna na área de reconhecimento biométrico de face, dado que manipular essas variações exige um grande número de técnicas para detecção da face, detecção da oclusão, reconstrução da imagem da face e por fim identificação do indivíduo. Atualmente, há progresso significativo em reconhecimento automático de faces em condições controladas. Entretanto, segundo Aisha et al. (2014), Min, Hadid e Dugelay (2014) e Zhang et al. (2018) não pode-se afirmar o mesmo da performance quando lidamos com condições não controladas, visto que as variações presentes nestes ambientes degradam a taxa de reconhecimento.

3.2 Detecção da face

Umas das atividades que devem ser realizadas na maioria dos sistemas de reconhecimento facial é a detecção da presença de face em uma determinada imagem. Detecção de face é uma técnica de processamento de imagem e visão computacional que se dedica a analisar a existência ou não de uma face em uma determinada imagem. Caso exista, deve-se retornar a localização espacial da mesma sobre a imagem. Uma vantagem de se detectar primeiramente a região da face em uma imagem é que após a detecção da face, a procura por pontos de referência em uma face fica restrita apenas a uma certa região da imagem, com isso reduzindo a influência de ruídos no processo de identificação.

A face é um objeto 3D, que recebe iluminação de inúmeras fontes de iluminação a partir de muitas direções. A tarefa de detecção de faces é considerada trivial para seres humanos, por ser uma atividade natural. Entretanto ao tentarmos reproduzir tal problemática em computadores ficamos sujeitos a inúmeros problemas. Segundo Benezeth et al. (2010) alguns destes problemas são variações de pose, expressão, iluminação e oclusões parciais, que dificultam a detecção automática da face.

A maioria das técnicas de reconhecimento facial assumem que as imagens de faces podem ser alinhadas e devidamente normalizadas (ambos geometricamente e fotometricamente), essa normalização é tipicamente realizada tomando por base a localização dos dois olhos na face. O esquema de detecção de face desenvolvido por (VIOLA; JONES, 2004) é considerado um marco, por possibilitar que faces possam ser detectadas em tempo real, mesmo na presença dos mais diversos fundos. Embora o algoritmo Viola-Jones tenha demonstrado excelente desempenho em aplicações em tempo real, ocorre uma degradação no seu desempenho quando confrontado com poses faciais não-frontais, mudanças de iluminação, oclusão, etc.

3.2.1 Viola-Jones

De maneira a possibilitar menores percentuais de influência do ambiente perante a tarefa de identificação nos sistemas biométricos baseados em faces, algumas abordagens vêm sendo propostas na literatura com vistas a segmentar adequadamente a região da face dentro de uma imagem. Dentre as estratégias, destaca-se o algoritmo Viola-Jones (VIOLA; JONES, 2004). Essa técnica possui como primeiro passo transformar a imagem de entrada em uma imagem integral, de maneira que cada pixel na nova imagem representa a soma dos valores de todos os pixels a sua esquerda e acima na imagem original, o qual é calculado por meio da Equação 1.

$$I_{integral}(x, y) = \sum_{x' \leq x, y' \leq y} I(x', y') \quad (1)$$

Na Equação 1, $I_{integral}(x, y)$ representa um pixel da imagem integral, $I(x', y')$ representa um pixel da imagem de entrada (ou seja, na imagem original). Um exemplo desse processo pode ser visualizado com o auxílio da Figura 9.

Figura 9 – Exemplo de construção de uma imagem integral. verde = 2, amarelo = 2+3, laranja = 2 + 4, e azul = 2+3+4+5

2	3	2	5
4	5	6	14

Fonte: Jonas Mendonça Targino, 2019

Após a obtenção da imagem integral pode-se realizar a soma de todos os pixels dentro de um retângulo apenas utilizando a soma de quatro valores. Sendo possível realizar a descoberta do valor de qualquer pixel do quadrado D na imagem original, com o auxílio da Equação 2. A descoberta do pixel D é representada na Figura 10.

Figura 10 – Cálculo da soma de um retângulo

2 A	5 B
6 C	14 D

Fonte: Jonas Mendonça Targino, 2019

$$I(D) = D - B - C + A \quad (2)$$

Analisando a Equação 2 pode-se observar que o retângulo A está presente nos retângulos B e C , torna-se necessário ao final adicionar o valor de A .

O algoritmo Viola-Jones utiliza como base retângulos para analisar determinada região da imagem. Podendo utilizar em cada análise dois ou mais retângulos seguindo diferentes tipos, em que cada tipo apresenta suas especificidades. Esses retângulos são conhecidos como características de Haar. Com o auxílio da Figura 11 é possível visualizar alguns tipos de características de Haar.

Figura 11 – Exemplos de características de Haar

Fonte: Jonas Mendonça Targino, 2019

O Viola-Jones possui como estratégia varrer a mesma imagem inúmeras vezes, alternando a cada vez o tamanho de suas janelas, objetivando com isso localizar as faces presentes na imagem. A principal iniciativa do algoritmo é gerar uma grande quantidade de janelas, analisá-las e verificar seu resultado. Ao apresentar-se resultados negativos é possível concluir que aquela região não seja uma face. Com isso, o algoritmo descarta as regiões que não são face, visando melhorar a eficiência computacional, as imagens de face de tamanho (128 x 128) são reduzidas para (24 x 24) pixels, sobre a qual são extraídas as diferentes características de Haar.

O algoritmo Viola-Jones utiliza um conjunto de classificadores fracos em cascata para formar um classificador forte, o qual é uma modificação do algoritmo Adaboost proposto por Freund, Schapire e Abe (1999). Cada nível do classificador em cascata busca analisar se naquela janela encontra-se uma face ou não. Ao identificar-se em qualquer um dos níveis que uma determinada janela é classificada como não face, aquela janela é automaticamente descartada. Entretanto, caso essa janela seja classificada como face, essa é repassada para o próximo nível da cascata. Na Figura 12 pode-se visualizar o procedimento de identificação de janelas como face ou não face. Uma característica importante desses classificadores é que as regiões que não são faces são descartadas logo nos primeiros níveis de classificação.

Figura 12 – Esquema de classificação em cascata do Viola-Jones

Fonte: Jonas Mendonça Targino, 2019. Imagem de face obtida da base AR (MARTINEZ, 1998)

Conforme já mencionado, o algoritmo Viola-Jones ao lidar com detecção de faces em ambientes controlados apresenta altas taxas de acerto. Entretanto ao lidar com ambientes não controlados essa estratégia apresenta algumas dificuldades de localização da face na imagem. Isso se deve as variações presentes nesses ambientes.

3.2.2 Skin Tone

Uma estratégia também utilizada no contexto de detecção de faces é o *Skin Tone*, essa técnica proposta por Cheddad et al. (2009) tem como objetivo detectar faces humanas a partir da análise da textura de cores de peles humanas. Essa técnica utiliza imagens tridimensionais de dimensões $(l, c, 3)$, de modo que l , c e 3 representam respectivamente a quantidade de pixels linha, quantidade de pixels em coluna e os 3 canais de cores RGB (do inglês: *Red*, *Green* e *Blue*).

Para detectar os pixels de pele essa técnica utiliza alguns passos, a saber:

1. Os valores de RGB são multiplicados pelos escalares (0.298, 0.587 e 0.140 respectivamente) e somados, gerando assim uma imagem bidimensional em escala de cinza I de dimensões (l, c) . Esses limiares foram adotados levando em consideração o grau de percepção do espectro visual humano conforme afirma Cheddad et al. (2009).

2. Na segunda etapa é gerada a imagem $\hat{I}$ de dimensões (d_1, d_2) , obtida por meio do valor máximo dos pixels dos canais G e B da imagem de consulta. Os valores do canal R são ignorados, visto que as maiores variações de iluminações podem se encontrar de forma significativa nesse canal. A Equação 3 apresenta tal processo;
3. Enquanto na terceira etapa é realizado o cálculo do erro do sinal, conforme Equação 4.
4. Na última etapa, é gerada a máscara de oclusão a partir da análise de limiar, esse limiar sendo disposto na literatura segundo Cheddar et al. (2009). O processo de construção da máscara pode ser construído com o auxílio da Equação 5.

$$I(\hat{i}, j) = \max(G(i, j), B(i, j)) \quad (3)$$

$$E = I - \hat{I} \quad (4)$$

$$I_{Binaria}(i, j) = \begin{cases} 1 & , se \quad 0.02511 \leq E(i, j) \leq 0.1177 \\ 0 & , cc \end{cases} \quad (5)$$

A Figura 13 ilustra a aplicação da técnica *Skin Tone* em imagens de face de um mesmo indivíduo com variações de iluminação, pose e oclusão. Nessa Figura podemos perceber que a técnica não se sobressai bem quando apresentada a imagens de face com variações de iluminação.

Figura 13 – Exemplos de faces após a aplicação da técnica *Skin Tone*

Fonte: Jonas Mendonça Targino, 2019

3.3 *Deteção de oclusão*

Oclusão é o posicionamento de algo, a frente do que desejamos visualizar, impedindo uma visão holística do que está por trás. Trazendo para o contexto de reconhecimento facial, Chandel e Vatta (2015) afirmam que a oclusão é o elemento básico que limita a informação da imagem. Segundo Ragashe, Goswami e Raghuwanshi (2015) existem dois tipos de oclusão, a primeira é a oclusão natural, esta refere-se a obstrução da visão sem nenhuma intencionalidade, como cicatrizes e pinturas ao considerarmos o contexto de face. O segundo tipo é a oclusão artificial, esta é o foco principal deste trabalho, e a mesma se refere ao bloqueio artificial ou intencional de cobertura da imagem facial. Alguns objetos como óculos, lenços, mãos e cabelos são responsáveis por gerar esse tipo de oclusão.

A oclusão de óculos é o tipo mais comum de oclusão que afeta significativamente a performance dos sistemas de reconhecimento (PARK et al., 2005). Segundo Venkatakrishnan et al. (2014), quando lidamos com sistemas de natureza não controlada a presença de oclusões é considerada frequente. Dessa forma, a oclusão parcial altera a aparência da face, causando reduções de desempenho do sistema, mas também levando a sérios problemas de segurança (OLOYEDE; HANCKE; KAPILESWAR, 2017).

Quando estamos diante de uma face com oclusão, uma das estratégias para realizar o reconhecimento do indivíduo é detectar a região ocluída e logo em seguida reconstruir a face, para que logo após seja possível realizar a identificação do indivíduo. De acordo com Wei et al. (2014) faces são facilmente ocluídas em cenários reais, alguns exemplos são objetos na frente da face (telefones celulares, alimentos e mãos), sendo muito comum diariamente as pessoas usarem acessórios faciais, tais como, óculos de sol, lenços, chapéus, cachecóis, máscaras e véus por motivos pessoais, culturais ou até mesmo estéticos. Esses objetos quando posicionados frente a face podem destruir a informação discriminante essencial da região facial, direcionando a estratégia de reconhecimento facial rumo a insuficiência de dados faciais, e conseqüentemente dificultando uma classificação correta, especialmente quando a oclusão ocupa regiões consideráveis da face. Srinivasan e Balamurugan (2014) e Tan et al. (2009) descrevem a variabilidade de condições e suas respectivas dificuldades ao se trabalhar com ambientes de coleta de imagens de face em ambientes não colaborativos com faces parcialmente ocluídas.

Lidar com oclusões parciais em imagens de face é uma tarefa complexa, pois além de identificarmos a face, temos que normalizá-la (pois a imagem da face pode estar rotacionada), segmentar a região da face, alinhá-la, identificar a região que a oclusão ocupa sobre a face, remover essa oclusão e reconstruir a parte ocluída da face. Estes passos atribuem complexidade a tarefa de reconhecimento de faces em ambientes irrestritos, sem contar que as oclusões parciais possibilitam localizações errôneas das características faciais. A oclusão parcial da face é um dos problemas mais desafiadores no reconhecimento facial (EKENEL; STIEFELHAGEN, 2009). Com o auxílio da Figura 14 é possível visualizar algumas imagens de faces parcialmente ocluídas.

Figura 14 – Exemplos de imagens faciais parcialmente ocluídas provenientes da base AR

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

3.4 Reconstrução da face ocluída

A reconstrução da face é uma das tarefas importantes perante o cenário de identificação de uma pessoa. Essa estratégia consiste em reconstruir a imagem da face de um indivíduo (cuja identidade muitas vezes não é conhecida).

Nessa tarefa exige-se um número considerável de imagens de face sem oclusão no conjunto de treinamento de modo a viabilizar o processo de reconstrução e com isso tentar aumentar a taxa de reconhecimento. Entretanto, nem sempre ao reconstruirmos uma imagem temos aumento na taxa de reconhecimento, visto que a depender do tamanho e tipo da oclusão, essa pode ocasionar na adição de pixels não relevantes na área não ocluída.

Dessa maneira ao reconstruirmos uma imagem, deve-se prestar atenção ao processo de reconstrução, tentando evitar possíveis perdas de dados que poderiam ser importantes.

Por isso, algumas técnicas de reconstrução substituem apenas as áreas ocluídas, mantendo as áreas não ocluídas da imagem original, e com isso evitando a inserção de pixels ruidosos nas posições dos pixels originais.

De acordo com Tajima et al. (2013) as técnicas de reconstrução são baseadas em subespaço e modelos. Nas abordagens baseadas em subespaço, os atributos são extraídos diretamente dos pixels da imagem da face e com isso, as imagens são projetadas em um espaço de faces. As técnicas que seguem essa abordagem são geralmente mais fáceis de serem implementadas, entretanto, as principais desvantagens dessas técnicas é sua alta sensibilidade às condições do ambiente, como ângulo de visualização da câmera, variações de iluminação, expressão e oclusão. Enquanto, as abordagens baseadas em modelo são construídos modelos que representam as imagens de treinamento, tendo como principal vantagem a baixa sensibilidade às variações das condições do ambiente (BUCIU, 2014).

3.5 *Técnicas para validação das imagens reconstruídas*

Na literatura existe uma quantidade considerável de métricas que possibilitam mensurar a qualidade visual de duas imagens (no caso, uma imagem comparada sem oclusão e uma imagem reconstruída), buscando medir o quão similares são aquelas duas imagens. Neste trabalho são apresentadas três métricas de comparação visual, as quais são descritas em detalhes abaixo.

3.5.1 Relação Sinal Ruído de Pico

Uma das técnicas utilizadas para avaliação da qualidade da imagem reconstruída é a Relação Sinal Ruído de pico (do inglês: *Peak Signal to Noise Ratio* - PSNR) proposta por (ASHIN; MORIMOTO; VAILLANCOURT, 2005). Essa estratégia realiza a validação das imagens reconstruídas com imagens do respectivo indivíduo na base de treinamento. Essa técnica analisa a variação entre o valor máximo de um sinal (MAX) e a potência do ruído de distorção que afeta a qualidade da imagem, ou seja, o erro quadrático Médio (EQM). Quanto maior o valor do PSNR, melhor é a qualidade da imagem reconstruída. O PSNR

é calculado usando a Equação 6. Caso o PSNR seja maior que 30, pode-se considerar que a imagem reconstruída possui boa qualidade.

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{EQM} \right) \quad (6)$$

O cálculo do EQM é apresentado na Equação 7, em que I_1 é a imagem original, I_2 é a imagem reconstruída e l e c são os números de linhas e colunas, respectivamente.

$$EQM = \frac{\sum_{l=1}^{d_1} \sum_{c=1}^{d_2} \left[I_1(l, c) - I_2(l, c) \right]^2}{d_1 d_2} \quad (7)$$

3.5.2 Similaridade Estrutural

Uma outra forma de mensurar a qualidade da imagem reconstruída é através da Similaridade Estrutural (do inglês: *Structural Similarity* - SSIM) proposta por (WANG et al., 2004). Essa estratégia mede a similaridade entre duas imagens, neste caso a imagem reconstruída e a imagem daquele respectivo indivíduo na base de treinamento. Essa métrica produz um valor no intervalo $[0,1]$ de modo que quanto mais próximo de 1 valor da SSIM, melhor é qualidade da imagem reconstruída. Logo o valor 1 significa que as duas imagens são iguais, já se o valor é 0 significa que as duas imagens não apresentam nenhuma correlação.

A SSIM possui como base o cálculo de três fatores em uma imagem: (i) iluminação; (ii) contraste; (iii) estrutura da imagem. O valor da SSIM é calculado a partir da uma combinação desses três fatores. A SSIM pode ser obtida por meio da Equação 8.

$$SSIM(I_1, I_2) = [l(I_1, I_2)]^\alpha \cdot [c(I_1, I_2)]^\beta \cdot [s(I_1, I_2)]^\gamma \quad (8)$$

De modo que α , β e γ são valores que por padrão apresentam valor igual a 1. A iluminação nessa técnica é representada pela Equação 9.

$$l(I_1, I_2) = \frac{2\mu_{I_1}\mu_{I_2} + C_1}{\mu_{I_1}^2 + \mu_{I_2}^2 + C_1} \quad (9)$$

Já o contraste e a estrutura de uma imagem podem serem obtidos com o auxílio das equações 10 e 11 respectivamente.

$$c(I_1, I_2) = \frac{2\sigma_{I_1}\sigma + C_2}{I_2\sigma_x^2 + \sigma_y^2 + C_2} \quad (10)$$

$$s(x, y) = \frac{\sigma_{I_1 I_2} + C_3}{\sigma_x \sigma_y + C_3} \quad (11)$$

Como visto que a SSIM pode ser obtida com o cálculo da iluminação, contraste e estrutura da imagem, logo é possível visualizar a fórmula completa da SSIM com o auxílio da Equação 12.

$$SSIM(I_1, I_2) = \frac{(2\mu_{I_1}\mu_y + C_1)(2\sigma_{I_1 I_2} + C_2)}{(\mu_{I_1}^2 + \mu_{I_2}^2 + C_1)(\sigma_{I_1}^2 + \sigma_{I_2}^2 + C_2)} \quad (12)$$

Já μ_x , μ_y são as médias locais da imagem I_1 e I_2 , σ_{I_1} , σ_{I_2} são os desvios padrão de I_1 e I_2 , e por último o $\sigma_{I_1 I_2}$ significa a covariância entre I_1 e I_2 . Enquanto C_1 e C_2 são responsáveis por estabilizar a divisão pelo denominador, de modo que $C_1 = (\kappa_1 L)^2$, $C_2 = (\kappa_2 L)^2$, $\kappa_1 = 0.01$, $\kappa_2 = 0.03$ e $C_3 = \frac{C_2}{2}$.

Segundo Thung e Raveendran (2009) a SSIM tenta simular o sistema visual humano por meio da análise da iluminação, contraste e estrutura da imagem fornecendo uma boa aproximação de percepção da diferença entre duas imagens.

3.5.3 Raiz Quadrada do Erro quadrático médio

A raiz quadrada do erro quadrático médio (do inglês: *Root-mean-square error* - RMSE) (CHAI; DRAXLER, 2014), é uma métrica muito utilizada para analisar a diferença de valores entre duas amostras. Esta também pode ser utilizada para análise da qualidade de duas imagens. O RMSE representa o desvio padrão entre as duas imagens, no caso a imagem modelo e a imagem reconstruída. Essa técnica no contexto de análise da qualidade das imagens busca verificar a magnitude das diferenças existentes entre duas imagens.

A equação do RMSE é dada pela da Equação 13, em que I_1 e I_2 são respectivamente a imagem modelo e a imagem reconstruída, enquanto d_1 e d_2 são as dimensões da imagem em linha (l) e coluna (c). Deste modo, é possível deduzir que o RMSE quando aplicado ao

contexto de análise de imagens é a raiz quadrada média da soma dos erros quadrados dos pixels. Assim, quanto maior o erro por pixel maior o RMSE.

$$RMSE = \sqrt{\frac{\sum_{l=1}^{d_1} \sum_{c=1}^{d_2} [I_1(l, c) - I_2(l, c)]^2}{d_1 d_2}} \quad (13)$$

Os valores dessa métrica são sempre positivos, e um valor 0 indica que as duas imagens são iguais. Logo quanto menor o RMSE, melhor é a qualidade da imagem reconstruída em termos de semelhança.

3.6 Análise de desempenho

Existem algumas métricas que possibilitam fazer uma análise um pouco mais detalhada de cada técnica em termos de reconhecimento, possibilitando inferências sobre o comportamento de cada uma a depender da necessidade de aplicação.

3.6.1 Taxa de falsa aceitação e falsa rejeição

Ao lidarmos com identificação, o modelo é treinado com algumas imagens de várias pessoas. Dessa forma para que um padrão (pessoa) possa ser reconhecido é necessário uma comparação de similaridade entre este e todos os *templates* / modelos existentes na base de dados, produzindo uma pontuação ou uma medida de similaridade que possa descrever de forma numérica o quão similar é o padrão de consulta e os *templates*. Logo, o sistema atribui ao padrão de consulta à pessoa com maior similaridade. De modo a evitar possíveis impostores (pessoas não contidas no conjunto), os sistemas biométricos utilizam algumas métricas. Essas métricas possuem um limiar de similaridade entre a imagem de consulta e o modelo, de modo que caso esse limiar não seja alcançado o padrão de consulta é rejeitado.

Esses limiares são usados para expressar a similaridade entre um padrão de entrada e os *templates*. Logo quanto maior a similaridade, maior será a semelhança entre o padrão e o *template*. Nos sistemas biométricos a pontuação de semelhança obtida pela análise de similaridade entre a consulta e o modelo é fundamental para separar os grupos de indivíduos presentes na base de indivíduos impostores.

Entretanto, segundo Costa (2011) em aplicações reais em alguns casos, os padrões biométricos dos impostores possuem pontuações mais altas do que alguns padrões de clientes. Por tal motivo, ao selecionarmos um limiar de classificação podemos aumentar o erro na tarefa de classificação. Por exemplo, a escolha de um limite alto pode assegurar que nenhum impostor com pontuação alta excederá tal limite, possibilitando que nenhum falso positivo seja aceito pelo sistema. Consequentemente, os padrões de usuários com pontuações mais baixas do que as pontuações mais altas dos impostores serão rejeitados, implicando em uma alta falsa rejeição. Logo, a escolha de um bom limite deve ser tomada com base em uma estratégia que reduza o índice de falsos reconhecimentos.

O trabalho de Prabhakar, Pankanti e Jain (2003) apresenta duas distribuições que podem ser utilizadas para descoberta de um bom valor de limiar. Uma delas é a taxa de falsa aceitação (do inglês: *False Acceptance Rate* - FAR) que é a medida de taxa de um sistema biométrico aceitar de maneira incorreta um indivíduo não autorizado (impostor), logo a FAR de um sistema é obtida por meio da razão entre o número de falsas aceitações pela quantidade de tentativas de reconhecimento.

A outra é a falsa rejeição (do inglês: *False Rejection Rate* - FRR) que significa o percentual de rejeições feitas incorretamente pelo sistema biométrico, de modo que o sistema falha em reconhecer uma pessoa autorizada, rejeitando essa pessoa como um impostor. Logo a FRR é declarada como número de falsas identificações dividido pelo número de falsos reconhecimentos. O ponto de cruzamento entre as curvas de FAR e FRR é chamado de taxa de erro igual (do inglês: *Equal Error Rate* - ERR), logo, o ponto ERR é considerado por Prabhakar, Pankanti e Jain (2003) limiar ótimo para o sistema. Nesse ponto o percentual de falsas aceitações e falsas rejeições são iguais. A Figura 15 ilustra as curvas de FAR e FRR, como também o ponto de cruzamento ERR das duas curvas.

Figura 15 – Curvas de FAR e FRR, com ponto de intersecção EER

Fonte: Jonas Mendonça Targino, 2019

Dado que o ERR é o limiar que pode ser tomado por base a depender do tipo de aplicação, a qual toma por base o princípio do que queremos tolerar a respeito da aplicação. Por exemplo, no caso de aplicações forenses, a falsa aceitação pode ser mais tolerada que a falsa rejeição (exemplo análise de retrato falado). Já em aplicações de alta segurança, a falsa aceitação não deve ser tolerada, pois existe a possibilidade de invasão do sistema. Dessa forma, é interessante percebermos que ao aumentar a taxa de semelhança maior que o EER maior será o número de rejeições de indivíduos cadastrados na base, e ao diminuirmos o EER maior será a aceitação de impostores pelo sistema de reconhecimento.

3.6.2 Matriz de confusão

Outra forma de mensurar o quão boa é uma determinada técnica na tarefa de identificação é analisar a matriz de confusão. Esta é responsável por fornecer uma visão geral da técnica, mostrando o número de classificações corretas, como também a classificação predita para cada classe, para um conjunto de exemplos.

A matriz de confusão representa em forma matricial dos rótulos de saída do classificador e a sua respectiva saída desejada para cada classe. A posição i (linha) da matriz apresenta os valores esperados para cada amostra, enquanto a posição j (coluna), apresenta os valores preditos pelo modelo. Dessa forma, cada posição (i, j) da matriz apresenta o número de amostras da classe i que foram preditas pelo modelo como sendo da classe j . Um fato interessante da matriz de confusão é que a quantidade presente na

diagonal principal ($i = j$) corresponde ao número de amostras que o modelo acertou e os demais elementos da matriz representam erros na classificação.

Para o problema de classificação binário, no qual a saída desejada pode ser codificada como 0,1, a matriz de confusão pode ser vista conforme a Figura 16, em que os valores VP, FN, FP e VN representam, respectivamente, verdadeiros positivos (amostras positivas classificadas corretamente), falsos negativos (quantidade de amostras que foram preditas pelo modelo como sendo da classe 0, quando na verdade pertenciam a classe 1), falsos positivos (quantidade de amostras que foram preditas como sendo da classe 1, mas eram da classe 0) e verdadeiros negativos (quantidade de amostras corretas que foram preditas pelo modelo como sendo da classe 0).

Figura 16 – Estrutura de uma matriz de confusão

		Classe Predita	
		Positivo	Negativo
Classe Real	Positivo	VP	FN
	Negativo	FP	VN

Fonte: Jonas Mendonça Targino, 2019

Uma das contribuições da matriz de confusão é a possibilidade de visualizar quais classes estão apresentando maior erro e maior acerto. Além disso, é possível com essa matriz obter algumas métricas que podem nos auxiliar na análise da técnica. Dentre estas medidas, podemos destacar:

- **Acurácia** - Significa a taxa de acerto das classes positivas e negativas perante todas as amostras. A acurácia pode ser calculada usando Equação 14, em que P é o número de amostras positivas e N é o número de amostras negativas.

$$acuracia = \frac{VP + VN}{P + N} \quad (14)$$

- **Sensibilidade** - Significa a probabilidade do classificador identificar corretamente os indivíduos da classe positiva. Essa métrica sendo obtida conforme a Equação 15.

$$sensibilidade = \frac{VP}{VP + FN} \quad (15)$$

- **Especificidade** - Significa a probabilidade do classificador identificar corretamente os indivíduos da classe negativa. A Equação 16 é usada para o cálculo da especificidade.

$$especificidade = \frac{VN}{VN + FP} \quad (16)$$

- **F1-score** - É uma métrica que utiliza como base a média ponderada entre a precisão e a sensibilidade. Podendo ser obtida usando a Equação 17. O F1-score retorna um valor no intervalo 0,1, de modo que 1 representa seu melhor valor (precisão e sensibilidade perfeitas) e 0 indica os piores resultados de precisão e sensibilidade.

$$f_1score = 2 \times \frac{precisao \times sensibilidade}{precisao + sensibilidade} \quad (17)$$

- **Coefficiente de correlação de Matthews** (do inglês: *Matthews correlation coefficient* - MCC) - É uma medida utilizada na área de aprendizado de máquina a qual possibilita mensurar a qualidade de duas classes na matriz de confusão. Essa métrica tem como base a estabilidade do desbalanceamento entre as classes, levando em conta os VP, VN, FP e FN. O MCC pode ser aplicado independentemente dos tamanhos diferentes entre as classes. O MCC retorna um valor no intervalo $[-1, +1]$, de modo que +1 representa uma predição perfeita, 0 indica que a predição é inferior a uma predição aleatória, e -1 indica discordância total entre o real e o predito. Essa métrica pode ser obtida conforme a Equação 18.

$$MCC = \frac{VP \times VN - FP \times FN}{\sqrt{(VP + FP)(VP + FN)(VN + FP)(VN + FN)}} \quad (18)$$

- **Curva Roc** - É um gráfico comumente utilizado que permite sumarizar a performance de uma determinada técnica a partir de vários limiares entre $[0,1]$. De modo que esse gráfico possui em um de seus eixos (eixo y) a taxa de verdadeiros positivos e em outro eixo (eixo x) a taxa de falsos positivos. Desse modo permitindo investigar os limiares de aplicação da técnica no mundo real. De modo que possamos enxergar limiares que condizem com as prioridades de aplicação. Em que essas prioridades possam ser definidas como percentual de falsos negativos ou falsos positivos.

4 Técnicas para detecção e reconstrução de oclusões parciais

Este capítulo possui como objetivo principal apresentar algumas técnicas para detecção e reconstrução de oclusões parciais em imagens de face. Todas as técnicas apresentadas neste capítulo são provenientes de uma revisão sistemática (RS) feita durante o desenvolvimento deste trabalho, esta RS encontra-se disponível no trabalho de (TARGINO; PERES; LIMA, 2018b).

4.1 Contextualização da literatura

Durante a elaboração deste trabalho analisou-se uma grande quantidade de trabalhos relacionados, a depender de sua temática junto a identificação biométrica da face. Com iniciativas a lapidar as técnicas analisou-se alguns trabalhos relacionados com iniciativas a implementação das mesmas para comparações futuras. Dentre os trabalhos podemos perceber que o artigo de Lai e Jiang (2013) apresenta uma técnica para detecção da oclusão utilizando um estimador robusto com regressão linear, em que o mesmo analisa os pixels correspondentes no conjunto de treinamento e os classifica como não ocluídos, diante disso a imagem analisada é classificada de acordo com a classe com menor erro de reconstrução. Já Zhang et al. (2016) utiliza sete Redes Neurais Convolutivas (do inglês: *Convolutional Neural Network* - CNN) para detecção da oclusão, dessas setes redes, três, duas e duas, são responsáveis por detectar respectivamente a cabeça, olhos e boca, utilizando a estratégia de *Max-pooling* como processo de discretização e redução do número de parâmetros para entrada na rede. O primeiro nível da CNN é responsável por rejeitar rapidamente a maioria das janelas de detecção, já o segundo nível julga se as janelas restantes são pontos faciais ou não.

Enquanto Wei et al. (2014) apresenta a estratégia DICW (do inglês: *Dynamic image-to-class Warping*), esta divide a imagem da face em P partes e logo em seguida analisa a diferença das tonalidades entre as partes a partir da manipulação de séries temporais, e logo após aplica distância Euclidiana para analisar a presença de possíveis oclusões nas partes da imagem. Já Sharma, Prakash e Gupta (2013) detecta a parte ocluída por meio da aplicação de um limiar na imagem em escala de cinza, com isso obtendo a máscara de oclusão.

A metodologia clássica para tratar o reconhecimento biométrico baseado em imagens de faces ocluídas consiste em encontrar características ou classificadores tolerantes a ruído. Dessa forma vários trabalhos dispostos na literatura têm demonstrado que os algoritmos locais são menos sensíveis a oclusões parciais. Buscando aplicar tais algoritmos, Penev e Atick (1996) propuseram Análise de Características Locais para extração de características usando estatísticas de segunda ordem. Já Martinez (2002) propôs uma abordagem que consiste em dividir a imagem da face ocluída em k regiões locais, sendo possível segmentar a região parcialmente ocluída por meio de um modelo probabilístico. Além disso, foi proposto uma ponderação para regiões locais a fim de fornecer robustez em problemas que envolvem variação de expressão. Uma extensão do trabalho de Martinez (2002) foi proposta por Tan et al. (2005a), em que o mesmo utilizou Mapas Auto-Organizáveis (do inglês: *Self Organizing Maps* - SOM) para apreender o subespaço ao invés de usar Gaussianas ou Mistura de Gaussianas como modelo probabilístico.

Paralelamente Kim et al. (2005) propôs um método chamado Análise de Componentes Independentes baseado em Saliências Locais, o qual emprega informação de saliências locais na extração dos componentes independentes. Enquanto Zhang et al. (2007) utilizou a divergência de Kullback-Leibler para estimar a distribuição de probabilidade de oclusões no espaço de característica, de modo a melhorar o método LGBPHS (do inglês: *Local Gabor Binary Pattern Histogram Sequence*) para a detecção da oclusão na imagem de face.

Em outro ângulo Shermina e Vasudevan (2012) dividem a imagem da face em B blocos e aplicam a técnica de correspondência por blocos para detecção da parte ocluída, utilizando uma máscara de tamanho (3×3) . Enquanto Chiang e Chen (2011) utilizam o método Descoberta Iterativa da Face (do inglês: *Iterative Face Recovery* - IFR), este método sendo responsável por criar conexões triangulares entre os pontos de referência da face, e com isso facilitar o processo de detecção da oclusão .

Em Tan et al. (2005b) aplicou-se o algoritmo SOM para projetar a relação topológica da face e assim localizar a região ocluída na imagem da face com o auxílio do KNN como classificador. Em contrapartida Huang e Yang (2012) utilizam Modelos Ocultos de Markov (do inglês: *Hidden Markov Models* - HMM), com esta técnica sendo possível identificar os componentes faciais por meio de uma gramática facial. Nessa técnica foi possível aplicar o Modelo de Oclusão Universal (do inglês: *Universal Occlusion Model* - UOM) para

identificar a localização da oclusão, como também qual componente facial ela está ocluindo. O trabalho de Zhang, Cerone e Gao (2006) apresenta a Memória de Kernel Associativo (do inglês: *Kernel Associative Memory* - KAM) com multi escala de transformação de Gabor. Já Su, Ai e Lao (2009) apresentam a técnica Alinhamento de Faces Multi-visões (do inglês: *Multi View Face Alignment* - MVFA) sendo responsável por alinhar a face e identificar pontos de oclusão, entretanto essa abordagem apresenta-se pouco voltada a oclusão, tendo maior ênfase para o alinhamento da face a partir das variações de pose.

Ao analisarmos o contexto de reconstrução da faces temos alguns trabalhos que são descritos com maiores detalhes logo em seguida, os quais tornaram-se essenciais para a realização deste trabalho. .

Dentre alguns trabalhos dispostos na literatura existem alguns que se destacam perante os demais. Como o trabalho de Deng, Dai e Zhang (2011) que utiliza um grafo espectral baseado na ideia de reconstrução da imagem, em que o algoritmo cria uma matriz esparsa para representar a parte parcialmente ocluída da imagem e com isso realizar a consulta no conjunto de treinamento, logo em seguida aplicando a topologia do grafo de Poisson na imagem do treinamento com maior similaridade para descoberta dos pixels ocluídos por meio da resolução de um sistema linear.

Sobre outra perspectiva Hosoi et al. (2012) apresentou a técnica FW-PCA (do inglês: *Fast Weighted - Principal Componente Analysis*), nesta técnica a imagem da face é reconstruída a partir do espaço de faces, a qual realiza a atualização a cada iteração, gerando uma máscara de oclusão robusta, a qual conseqüentemente possibilita melhores imagens reconstruídas. Zhang, Cerone e Gao (2006) aplicam modelos de KAM baseadas em transformações de Gabor, em que as imagens de face são decompostas em representações multi-escala pela transformação de Gabor e depois modelada pelas KAM para sua posterior reconstrução.

Em outro contexto, Alyüz et al. (2012) e Alyuz, Gokberk e Akarun (2013) utilizaram a técnica Ponto Iterativo mais Próximo (do inglês: *Iterative Closest Point* - ICP) para detecção da oclusão, e para reconstrução da face aplicaram *Gappy* PCA com iniciativas a encontrarem melhores coeficientes de combinação linear com redução do erro de reconstrução, em que esses coeficientes passaram pelo processo de minimização do gradiente. Paralelamente, Bellil, Brahim e Amar (2016) aplicam comparações de coeficientes Wavelet da imagem ocluída com todas as imagens do conjunto de treinamento, e para a tarefa

de reconstrução da face utilizaram a técnica GWNN (do inglês: Gappy Wavelet Neural Network).

Enquanto Min, Hadid e Dugelay (2011) aplicaram um modelo que procura por partes ocluídas na imagem facial, de modo que esse modelo foi construído fazendo uso das técnicas Gabor Wavelet para análise da textura, PCA para projeção das faces no espaço de faces e o classificador SVM para classificação dos pixels ocluídos a cada iteração. Logo após esse processo são realizados os testes de reconhecimento com as imagens resultantes. Storer et al. (2009) propôs o FRPCA (do inglês: *Fast Robust PCA*), o qual detecta os pixels efetivos usando uma quantidade K de pequenos espaços de faces computados pela seleção de P pixels selecionados aleatoriamente, de modo que o conjunto de treinamento e teste fazem uso do processo de detecção dos pixels efetivos. A base dessa técnica realiza o armazenamento de todos os pequenos subespaços computados do conjunto de treinamento para a cada iteração incrementar o número de pixels efetivos.

Já em Fidler, Skocaj e Leonardis (2006) foi proposto a combinação de métodos baseados em subespaço, como Análise de Componentes Principais (do inglês: Principal component Analysis - PCA), com métodos que visam a discriminação, como Análise de Discriminante Linear (do inglês: *Linear Discriminant Analysis* - LDA), objetivando melhor reconstrução das imagens de face. Por outro lado, Jia e Martinez (2009) propôs emprego de Máquinas de Vetores Suporte em cenários em que a oclusão pode ocorrer em ambos os conjuntos de treinamento e teste. Neste caso, problema de oclusão foi tratado como um problema de reconstrução e a classificação foi realizada de acordo com o erro de reconstrução obtido para a imagem de teste.

Paralelamente Shermina e Vasudevan (2012), Chiang e Chen (2011) utilizam como método de reconstrução PCA, utilizando os *Eigenfaces* com maiores autovalores para reconstruir as imagens parcialmente ocluídas. Enquanto Sharma, Prakash e Gupta (2013) utilizam filtros de Gabor com oito variações de ângulos gerando oito conjuntos de treinamento, utilizando a técnica PCA para projetar oito subespaços referentes aos respectivos conjuntos de treinamento. Dessa forma reconstruindo as imagens e utilizando o espaço de face que apresentou melhores níveis de reconstrução para a tarefa de classificação.

Sobre a perspectiva de detecção dos pontos faciais reconstrução da face no trabalho Hwang et al. (2000) é proposto um método para reconstruir faces parcialmente ocluídas por meio da seleção manual de alguns pontos característicos na região facial, sendo baseado

na forma da face. Dessa forma sendo possível estimar os coeficientes de combinação linear das faces de treinamento por meio das informações obtidas com o modelo.

4.2 Técnicas para detecção de oclusões parciais

Dos trabalhos dispostos na literatura para detecção da oclusão neste trabalho foram utilizadas três técnicas, as quais são descritas em maiores detalhes logo abaixo:

4.2.1 Skin Tone

A técnica *Skin Tone* (CHEDDAD et al., 2009) foi a primeira técnica a ser utilizada neste trabalho para detecção da oclusão na imagem de face, essa técnica em sua ideia original abordada na subseção 3.2.2 é utilizada para detecção da face, entretanto também pode ser utilizada para detecção da oclusão. Após a aplicação da técnica Viola-Jones para detecção da face, utilizamos a técnica *Skin Tone* para análise de seu comportamento perante a tarefa de detecção da parte ocluída. Para detecção da oclusão com essa técnica é obrigatório que a imagem de consulta esteja em RGB.

4.2.2 Limiarização

Essa técnica utilizada por Sharma, Prakash e Gupta (2013) para detecção da parte ocluída, tendo como princípio a aplicação de um limiar em uma imagem parcialmente ocluída em escala de cinza para construir a máscara de oclusão da imagem. Neste trabalho a partir de inúmeros experimentos verificou-se que o limiar igual a 78 seria um bom limiar de aplicação da técnica para cenários controlados. Entretanto, essa técnica ao ser apresentada a imagens de face com variações de iluminação e oclusão apresentou resultados desfavoráveis de segmentação da parte ocluída na imagem da face. A máscara de oclusão dessa técnica pode ser gerada conforme a Equação 19.

$$I_{Binaria}(i, j) = \begin{cases} 0 & \text{se imagem}(i, j) \leq \text{limiar} \\ 1 & \text{caso contrario} \end{cases} \quad (19)$$

Inicialmente nos experimentos foi utilizada essa técnica para tentar detectar a oclusão, entretanto a mesma apresentou queda de performance quando submetida a detecção de oclusões com tonalidades próximas a cores da pele humana, como também oclusões com iluminações. Essa técnica apresentou melhores segmentações da parte parcialmente ocluída do que a técnica *Skin Tone*.

4.2.3 Algoritmo de correspondência dos blocos

Outra técnica de detecção da oclusão é o Algoritmo de Correspondência dos Blocos (do inglês: *Block Matching Algorithm* - BMA), proposta por (SHERMINA; VASUDEVAN, 2012), a qual se estabelece que ao compararmos blocos de pixels de uma imagem parcialmente ocluída com os respectivos blocos em uma imagem sem oclusão é possível detectar os pixels da região ocluída. Essa técnica é responsável por realizar a divisão da imagem I em K blocos de tamanho $(N \times N)$. Na Equação 20 é representada a estrutura da imagem I ao ser particionada em K blocos sem sobreposição.

$$I = \{Ib_1, Ib_2, \dots, Ib_K\} \quad (20)$$

No BMA divide-se a imagem em blocos de tamanhos similares que são utilizados para detectar a oclusão na imagem da face. Como estratégia de comparação entre os blocos com vistas a detectar a parte ocluída e não ocluída é utilizada a distância Euclidiana, para analisar a similaridade entre as imagens dos blocos.

Para análise de similaridade e correspondência entre os blocos compara-se cada imagem ocluída (imagem de consulta), com uma imagem presente na base de dados. Visto que uma imagem de consulta Υ foi dividida em K blocos descritos conforme a Equação 21.

$$\Upsilon = \{\Upsilon b_1, \Upsilon b_2, \dots, \Upsilon b_K\} \quad (21)$$

Então comparamos cada bloco da imagem de consulta e a imagem presente no banco de dados, essa comparação sendo possível com auxílio das métricas da distância Euclidiana, conforme descrito na Equação 22.

$$Ed_a = \sqrt{\sum (Ib_a - \Upsilon b_a)^2} \quad (22)$$

Podemos visualizar com o auxílio da Figura 17 o processo de detecção da oclusão por meio da técnica BMA, de modo que para exemplificar foram utilizados 16 blocos para cada uma das imagens. A partir dessa visualização pode-se perceber que é realizada a verificação distância euclidiana entre todos os pixels do bloco $B1$ da imagem parcialmente ocluída com os pixels pertencentes ao bloco $B2$ da imagem sem oclusão e assim sucessivamente.

Figura 17 – Esquema do BMA

Fonte: Jonas Mendonça Targino, 2019

Em que a é o número dos blocos das imagens. Após o cálculo da distância Euclidiana aplica-se um limiar para remover a oclusão. Na Figura 18 apresenta-se na primeira linha imagens com oclusões parciais, e na terceira linha imagens com suas respectivas oclusões detectadas por meio de uma máscara de tamanho (2×2) , ou seja, $N = 2$.

Figura 18 – Detecção da parte ocluída com a técnica de detecção por blocos

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas após aplicação do Viola-Jones na base AR (MARTINEZ, 1998)

4.3 Técnicas de reconstrução baseadas em subespaço

As técnicas de reconstrução baseadas em subespaço possuem como princípio fundamental a projeção das imagens em um espaço de faces. Dessa forma, ao lidarmos com faces parcialmente ocluídas, a modelagem segue a mesma estrutura, com diferencial que a imagem de entrada possui pixels pretos na parte ocluída, com iniciativas que aqueles pixels não influenciem erroneamente na projeção da imagem facial. Na Figura 19 é possível visualizar a forma de projeção de uma imagem sem oclusão e uma imagem parcialmente ocluída no subespaço, contendo dois *eigenfaces*. O DFFS representa uma métrica de distância daquela imagem para espaço de faces.

Figura 19 – Projeção de uma imagem no subespaço

Fonte: Jonas Mendonça Targino, 2019. Adaptado de Chollet et al. (2007)

4.3.1 Eigenfaces

Eigenfaces proposto por Turk e Pentland (1991) é uma técnica de reconstrução de faces, sendo a primeira a ser vista como um sucesso, essa técnica utiliza um conjunto de Eigenfaces que são projeções de faces, em que essas projeções quando combinadas linearmente conseguem representar cada imagem do conjunto de faces. O *Eigenfaces* utiliza princípios do PCA com iniciativas a projetar as imagens em um espaço de características de baixa dimensão, partindo da ideia que a imagem na alta dimensão pode ser descrita por variáveis correlacionadas, sendo necessário poucas dimensões para representação da maior parte da informação da imagem, nesse meio termo atuando o PCA, de modo a encontrar as direções com maior concentração dos dados, denominados componentes principais.

Na técnica *Eigenfaces* todas as M imagens de treinamento de face são de dimensões $(l \times c)$, cada uma dessas imagens deve ser transformada em um vetor Γ_i com dimensões $F = (l \cdot c)$. Dessa forma com todos os M Γ_i , ou seja todas as imagens transformadas em vetor, é possível obter a Matriz Γ da forma $\Gamma = [\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M]$. A partir da matriz

abaixo é possível visualizar o processo de transformação de uma imagem I_i de dimensões $(l \times c)$ em um vetor Γ_i de dimensões $(F \times 1)$

$$I_i = \begin{bmatrix} a_{11} & \dots & a_{1c} \\ : & : & : \\ a_{l1} & \dots & a_{lc} \end{bmatrix}_{l \times c} \rightarrow \begin{bmatrix} a_{11} \\ : \\ a_{l1} \\ : \\ a_{1c} \\ : \\ a_{lc} \end{bmatrix}_{F \times 1} = \Gamma_i$$

Tendo um conjunto de M imagens de treinamento a Equação 23 apresenta o cálculo da imagem média μ das faces. Enquanto a Figura 20 ilustra a imagem média obtida de um conjunto de treinamento.

$$\mu = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (23)$$

Figura 20 – Exemplo de formação da imagem média dado um conjunto de imagens

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

Logo após a imagem média das faces ser calculada, faz-se necessário calcular a dissimilaridade entre cada imagem da face Γ_i e a imagem média μ , essa proposta de subtração de cada imagem pela imagem média faz-se necessária para distinguir as características de cada face e com isso remover as informações em comum. É possível visualizar o cálculo da matriz de dissimilaridade A conforme a Equação 24.

$$A = [\Theta_1, \Theta_2, \dots, \Theta_M] \text{ sendo } \Theta_i = \Gamma_i - \mu, \quad (24)$$

Com a matriz A de dissimilaridade é possível obter os autovetores e autovalores a partir da matriz de covariância C , que pode ser obtida por meio da Equação 25.

$$C = A \cdot A' \quad (25)$$

Entretanto, encontrar os autovalores e autovetores é uma tarefa muito custosa para o tamanho das imagens utilizadas, visto que a matriz de covariância será da ordem $(F \times F)$, assim uma maneira simplificada foi adotada por Turk e Pentland (1991), em que dada a matriz de covariância podemos representá-la por meio do produto entre $A' \cdot A$, gerando uma matriz $(M \times M)$ que é inúmeras vezes menor. Após essa mudança de operações para adquirir a matriz de covariância e seus subsequentes autovetores é possível obter os *Eigenfaces* a partir da multiplicação da matriz A pelos autovetores da matriz C representados por β com a mesma dimensão de C , como apresenta a Equação 26. Com base na fórmula podemos reduzir o número de *Eigenfaces* para um valor k , em que esse valor significa que esses k *Eigenfaces* são os 95% mais representativos do conjunto.

$$\Phi = A \cdot \beta$$

dessa forma Φ possui M Eigenfaces, em que cada M_i Eigenface representa

a projeção da imagem I_i

$$\Phi = [v_1, v_2 \cdots v_M]$$

logo selecionamos os k melhores Eigenfaces, ou seja os com maiores autovalores, que representam 95% do conjunto

$$\Phi = [v_1, v_2 \cdots v_k] \quad (26)$$

Após encontrados os k melhores *Eigenfaces* representados por Φ , temos a representação das imagens da face em formas de sombras como podemos ver na Figura 21.

Figura 21 – Exemplos de 10 *eigenfaces* da base de dados *AR* com 100 indivíduos

Fonte: Jonas Mendonça Targino, 2019

Para reconstruirmos uma imagem precisamos da imagem média do conjunto μ , dos Eigenfaces Φ , e dos seus respectivos coeficientes de combinação linear y . O vetor de coeficientes de combinação linear segue a forma $y = [y_1, y_2, \dots, y_k]$, de modo que cada coeficiente de combinação linear y_i corresponde ao Eigenface v_i . Cada coeficiente y_i pode ser obtido por meio da Equação 27, de modo que Υ e v_i representam respectivamente a imagem de consulta e o *Eigenface* v_i .

$$y_i = (\Upsilon - \mu) \cdot v_i \quad (27)$$

Ao encontrarmos os coeficientes de combinação e os *Eigenfaces* podemos reconstruir uma imagem de consulta Υ de acordo com a Equação 28, de modo que a imagem reconstruída é obtida por meio da soma da imagem média com o somatório dos K melhores Eigenfaces v pelos seus respectivos coeficientes de combinação linear y . Nessa fórmula K representa os K melhores *Eigenfaces* selecionados.

$$\hat{\Upsilon} = \mu + \sum_{i=1}^K y_i \cdot v_i \quad (28)$$

Ao realizarmos a reconstrução da imagem de face e projetarmos essa imagem no espaço de faces podemos obter sua distância para o espaço de faces (do inglês: *Distance from face space* - DFFS), esta medida sendo responsável por avaliar se uma dada imagem

pode representar uma face ou não, mediante análise da distância entre o espaço de faces e tal imagem. A Equação para obtenção do DFFS pode ser vista na Equação 29.

$$DFFS = \left| \Upsilon - \hat{\Upsilon} \right| \quad (29)$$

É importante notar que quanto maior o DFFS de uma imagem de consulta maior é a possibilidade de existência de oclusão naquela imagem, de modo que faces ocluídas tendem a não combinar linearmente com *Eigenfaces* calculados com exemplos de imagens não ocluídas.

4.3.2 Gappy PCA

Outra técnica de reconstrução da imagem da face é o GPCA (do inglês: *Gappy Principal Component Analysis*) (COLOMBO; CUSANO; SCHETTINI, 2009). Essa estratégia tem como base um conjunto de imagens de faces ocluídas $\{\Upsilon_1, \Upsilon_2, \dots, \Upsilon_N\}$, em que cada face possui um vetor y de coeficientes, e a tarefa principal dessa estratégia é encontrar um vetor de y que minimize o erro de reconstrução da imagem. Assim, uma imagem de face com oclusão pode ser restaurada com o auxílio da combinação linear entre um vetor de coeficientes y com os *Eigenfaces*, conforme a Equação 30. Nesta Equação a variável μ e K representam respectivamente a imagem média do conjunto de imagens sem oclusão e o número de *Eigenfaces* selecionados.

$$\Upsilon + e = \mu + \sum_{i=1}^K y_i \cdot v_i \quad (30)$$

Para calcular os coeficientes y_i , o DFFS deve ser minimizado. Contudo, o DFFS é calculado a partir das imagens com oclusões parciais. Para realizar a reconstrução da imagem faz-se necessário calcular o produto *gappy* dado por $(u, v)_z$, conforme Equação 31, em que o vetor z é um vetor binário, contendo 0 caso a imagem Υ na posição i for 0, ou seja, a oclusão foi removida na fase de detecção da oclusão, caso contrário $z_i = 1$. De acordo com a Equação 31 os termos u_i e v_i são os *Eigenfaces*, e F é a quantidade de pixels da imagem.

$$(u, v)_z = \sum_{i=1}^F u_i \cdot v_i \cdot z_i \quad (31)$$

Conforme mencionado os coeficientes y_i são definidos de modo a minimizar o $\|e\|_z^2$, conforme a Equação 32.

$$\|e\|_z^2 = \left\| -\Upsilon + \mu + \sum_{i=1}^K y_i v_i \right\|_z^2 = \|\Upsilon - \mu\|_z^2 - 2 \sum_{i=1}^K \sum_{j=1}^K y_i y_j (v_j, v_i)_z \quad (32)$$

Após o cálculo da derivada de $\|e\|_z^2$ em relação a y_i , considerando as derivadas parciais nulas, temos a Equação 33.

$$\frac{\partial \|e\|_z^2}{\partial y_i} = -2(\Upsilon - \mu, v_i)_z + 2 \sum_{j=1}^K y_j (v_j, v_i)_z, \text{ para cada } i \text{ em } \{1, 2, \dots, K\} \quad (33)$$

Após os coeficientes y_i encontrados por meio da minimização da Equação 33, é possível reconstruir a imagem com o auxílio da Equação 34.

$$\hat{\Upsilon} = \mu + \sum_{i=1}^K y_i \cdot v_i \quad (34)$$

4.3.3 Asymmetrical PCA

Análise dos componentes principais Assimétricos (do inglês: *Asymmetrical Principal Component Analysis* -APCA) proposto por Söderström e Li (2011) baseado no PCA (JOLLIFFE, 2002). Com a técnica APCA é possível reconstruir regiões com oclusões parciais em imagens de face levando em consideração as regiões não ocluídas, de tal modo que a intensidade dos pixels das regiões não ocluídas é utilizada para estimar as regiões com oclusões parciais. A ideia principal do APCA surge a partir da criação de dois autovetores, um a partir dos pixels não ocluídos da imagem ocluída em que os vetores são ortogonais entre si e o outro, chamado de pseudo autovetor, ou autovetor falso, sendo construído a partir das imagens ocluídas. Dada a imagem Υ , podemos representar a parte não ocluída de Υ como Υ^{no} . De modo que Υ^{no} é modelado em um espaço vetorial $\Phi^{no} = \{\phi_1^{no}, \phi_2^{no}, \phi_3^{no}, \dots, \phi_N^{no}\}$, a Equação 35 apresenta a função responsável pelo mapeamento, em que β_{ij}^{no} são os autovetores da matriz de covariância $A = \{ (\Upsilon_i^{no} - \Upsilon_{\underline{o}}^{no})^T (\Upsilon_j^{no} - \Upsilon_{\underline{o}}^{no}) \}$

e $\Upsilon_{\underline{o}}^{no}$ é a média das regiões não ocluídas, o cálculo da média é apresentado na Equação 36.

$$\Phi^{no} = \sum_i \beta_{ij}^{no} (\Upsilon_i^{no} - \Upsilon_{\underline{o}}^{no}) \quad (35)$$

$$\Upsilon_{\underline{o}}^{no} = \frac{1}{n} \sum_{j=1}^K (\Upsilon_j^{no}) \quad (36)$$

Os valores dos autovetores das partes não ocluídas são utilizados para torná-los ortogonais, enquanto as partes ocluídas são modeladas a partir das tonalidades dos pixels das partes não ocluídas. Com isso, o pseudo autovetor pode ser construído conforme apresenta a Equação 37, em que Υ_i é a imagem original (face com oclusão) e $\Upsilon_{\underline{o}}$ é a média das imagens originais.

$$\Phi_j^P = \sum_i \beta_{ij}^{no} (\Upsilon_i - \Upsilon_{\underline{o}}) \quad (37)$$

A projeção é usada para extrair coeficientes $\{y_j^{no}\}$ do autovetor Φ_j^{no} , conforme apresentado na Equação 38.

$$y_j^{no} = (\Upsilon_i^{no} - \Upsilon_{\underline{o}}^{no})^T \Phi_j^{no} \quad (38)$$

Ao final, podemos reconstruir a imagem utilizando a Equação 39, em que K nessa Equação se refere a quantidade de pseudo autovetores selecionados para a reconstrução.

$$\hat{\Upsilon} = \mu + \sum_{j=1}^K y_j^{no} \Phi_j^P \quad (39)$$

4.3.4 Recursive PCA

A ideia principal do *Recursive PCA* proposto por Park et al. (2005) é gerar uma nova face, sendo obtida por meio da máscara da imagem parcialmente ocluída. Nessa estratégia para a face parcialmente ocluída, deve-se encontrar seus coeficientes de combinação linear conforme a Equação 40, em que y representa os coeficientes de combinação linear da

imagem parcialmente ocluída, Φ é o espaço de faces, Υ é a face de entrada, e μ é a imagem média do conjunto de treinamento.

$$y = \Phi^T \cdot (\Upsilon - \mu) \quad (40)$$

Após realizarmos a reconstrução da imagem com o auxílio da Equação 41, temos a imagem reconstruída $\hat{\Upsilon}$.

$$\hat{\Upsilon} = \mu + \sum_{i=1}^K y_i \cdot v_i \quad (41)$$

Os valores da máscara de oclusão z são binários ou seja 0 ou 1, valor 0 significa cor preta e indica que aquele pixel está ocluído, já o valor 1 equivale a cor branca e indica que aquele pixel não está ocluído. Simplificando, se a região ocluída é conhecida, os valores de pesos da região ocluída é 1, e as outras regiões recebem 0. Atuando como a máscara de oclusão.

Por fim o Recursive PCA multiplica a máscara de oclusão z pela imagem de entrada Υ com iniciativas a recuperar a região não ocluída da imagem parcialmente ocluída. Logo após associa-se a parte não ocluída da imagem ocluída, com a parte reconstruída correspondente a máscara de oclusão da imagem reconstruída. Pode-se visualizar a equação matricial desse processo na Equação 42, em que $\hat{\Upsilon}^1$ é o resultado da face reconstruída na primeira iteração.

$$\hat{\Upsilon}^1 = z \cdot \Upsilon + (1 - z) \cdot \hat{\Upsilon} \quad (42)$$

Como estratégia para verificar o quão boa é a qualidade da imagem reconstruída frente a imagem parcialmente ocluída utilizou a variável D , a mesma é apresentada na Equação 43.

$$D = \max(|\hat{\Upsilon}^t - \hat{\Upsilon}^{t-1}|) \quad (43)$$

Com a região ocluída detectada e atribuída a variável z , então inicia-se o processo de compensação da reconstrução a cada iteração da execução do algoritmo. Na primeira iteração do algoritmo utiliza-se a imagem parcialmente ocluída para reconstruir, entretanto após a segunda iteração a imagem reconstruída que é utilizada com motivações a

tentar encontrar uma imagem com melhor nível de reconstrução. Esse processo pode ser visualizado com o auxílio da Equação 44.

$$\begin{cases} \hat{\Upsilon}^1 = z \cdot \Upsilon + (1 - z) \cdot \hat{\Upsilon} , & \text{se } (t = 1) \\ \hat{\Upsilon}^t = z \cdot \Upsilon + (1 - z) \cdot \hat{\Upsilon}^{t-1} , & \text{se } (t > 1) \end{cases} \quad (44)$$

Como processo de parada desse algoritmo é utilizada a variável D , enquanto ela for maior que um limiar ε o algoritmo continua realizando buscas por melhores soluções a cada iteração.

4.3.5 *Fast Recursive PCA*

A mudança do PCA clássico para o *Fast Recursive PCA* (WANG; TAO, 2007) é que a imagem reconstruída depende da máscara de oclusão da imagem na iteração t e da imagem na iteração $t+1$, com iniciativas a apresentar estabilidade de reconstrução, como também garantir que a imagem reconstruída possua os pixels não ocluídos em suas respectivas posições da imagem, quanto aos pixels ocluídos, esses sim que devem ser modificados com o algoritmo de reconstrução, favorecendo melhores imagens reconstruídas. Na Equação 45 pode-se visualizar a formulação matemática deste problema. Neste exemplo z , Υ , $\hat{\Upsilon}$ e $\hat{\Upsilon}^1$ representam respectivamente a máscara de oclusão, a imagem de consulta, a imagem reconstruída, e a imagem reconstruída na primeira iteração.

$$\hat{\Upsilon}^1 = z \cdot \Upsilon + (1 - z) \cdot \hat{\Upsilon} \quad (45)$$

Os coeficientes de combinação linear y^t são calculados tomando por base a imagem $\hat{\Upsilon}^t$ reconstruída na iteração t , como demonstra a Equação 46, de modo que no instante $t = 0$ o y é calculado tomando por base a imagem de consulta, entretanto após a iteração 0, o y^t é calculado tomando por base a imagem reconstruída $\hat{\Upsilon}^t$ no instante t .

$$\begin{cases} y = \Phi' \cdot (\Upsilon - \mu) , & \text{se } (t = 0) \\ y^1 = \Phi' \cdot (\hat{\Upsilon}^1 - \mu) , & \text{se } (t = 1) \\ y^t = \Phi' \cdot (\hat{\Upsilon}^t - \mu) , & \text{se } (t > 1) \end{cases} \quad (46)$$

Essa técnica possui como ponto de parada quando a diferença máxima absoluta entre os coeficientes de combinação linear sucessivos for menor que o limiar ε , como podemos visualizar na Equação 47.

$$D = \max(|y^{t+1} - y^t|) < \varepsilon \quad (47)$$

Outra característica importante desta técnica é a multiplicação de um α pela subtração dos coeficientes de combinação linear da iteração t pelos coeficientes da iteração $t - 1$. Essa estratégia possui iniciativas a minimizar os coeficientes de combinação linear e com isso produzir uma melhor reconstrução. Nessa técnica a velocidade de convergência é acelerada devido a diferença entre os coeficientes de combinação linear sucessivos. Na Equação 48 pode-se enxergar todos esses passos.

$$\hat{Y}^{t+1} = \mu + \sum_{i=1}^K [y_i^t + \alpha \cdot (y_i^t - y_i^{t-1})] \cdot v_i \quad (48)$$

Com o auxílio da Figura 22 podemos visualizar a velocidade de convergência da técnica *Fast Recursive PCA*, também podemos visualizar como a variável D varia conforme cada iteração perante minimização dos coeficientes de combinação linear.

Figura 22 – Exemplo do processo de reconstrução com o Fast Recursive PCA

Fonte: Jonas Mendonça Targino, 2019

4.3.6 Fast Robust PCA

Essa técnica também é conhecida como FRPCA (STORER et al., 2009). E possui como base a detecção dos pixels efetivos da imagem parcialmente ocluída usando a combinação de pequenos espaços de faces gerados por amostras de pixels do conjunto de treinamento selecionadas de forma aleatória, de modo que após esse processo a imagem com oclusão é reconstruída a cada iteração a partir da detecção dos pixels efetivos. Na

Figura 23 são apresentados o diagrama de fluxo da técnica FRPCA, a qual consiste dos (i) processo de treinamento e (ii) processo de reconstrução.

Figura 23 – Diagrama de fluxo do processo de reconstrução utilizando a técnica FRPCA

Fonte: Jonas Mendonça Targino, 2019, adaptada de Hosoi et al. (2012)

Processo de treinamento

N essa etapa, inicialmente o espaço de faces E é calculado usando todas as imagens do conjunto de treinamento. Logo após K pixels são extraídos de cada imagem do conjunto de treinamento de acordo com S padrões de subamostras. Dessa forma, com as S subamostras do conjunto de treinamento para cada uma delas é gerado seu respectivo espaço de faces, embora esse seja um espaço reduzido, de forma $F_s[s = 1, \dots, S]$. Na Figura 24 é apresentado o processo de treinamento da técnica FRPCA.

Figura 24 – Treinamento da técnica Fast Robust PCA

Fonte: Jonas Mendonça Targino, 2019, adaptada de Storer et al. (2009)

Processo de reconstrução

Na segunda etapa o conjunto $\Upsilon_s = \{s = 1, \dots, S\}$ é gerado para imagem parcialmente ocluída, para S padrões de amostragem aleatória usadas no processo de treinamento. De modo que para Υ_s existe uma imagem reconstruída $\hat{\Upsilon}_s$ que é estimada por meio da correspondência do seu respectivo espaço de faces F_s . Então, podemos calcular o erro de reconstrução daquela imagem reconstruída conforme a Equação 49.

$$r_s = \left| \Upsilon_s - \hat{\Upsilon}_s \right| \quad (49)$$

Com erro de reconstrução de cada amostra r_s os pixels efetivos são detectados desse modo o pixel j da subamostra Υ_s é removido como um pixel faltante se seu erro de reconstrução r_{sj} satisfazer as condições da Equação 50.

$$r_{sj} > \mu_s \bar{r}_s \text{ ou } r_{sj} > \bar{r} \quad (50)$$

Em que $\bar{r}_s$ representa a média do erro de reconstrução da amostra Υ_s , $\bar{r}$ é a média de todos os erros de reconstrução, μ_s é um parâmetro que depende de $\bar{r}_s$. Dessa forma os pixels restantes, ou seja, os candidatos a pixels efetivos, são selecionados a cada iteração, de modo que os P pixels remanescentes são selecionados em ordem ascendente de erro de reconstrução da amostra r_s , para que os mesmos possam se tornar pixels efetivos. Então, em cada iteração pontos com baixo erro de reconstrução que foram descartados anteriormente, podem ser inseridos para $\mathbf{r}$, e com isso tentar conseguir melhores qualidades de reconstruções.

Desse modo, a imagem ocluída é reconstruída tomando por base a Equação 50 e dessa forma estimados os H pixels efetivos. Portanto, os pixels faltantes podem ser incluídos como pixels efetivos H a cada iteração a depender de seu erro de reconstrução a cada iteração. Logo, após T iterações podemos obter a imagem reconstruída. É importante notar que nessa técnica as iterações são repetidas até que o número de pixels efetivos seja reduzido para o número especificado. A Figura 25 ilustra o comportamento da técnica FRPCA com seu processo de inclusão dos pixels efetivos a cada iteração.

Figura 25 – FRPCA e seu comportamento frente a detecção da oclusão a cada iteração

Fonte: Jonas Mendonça Targino, 2019

4.3.7 Fisherfaces

O algoritmo Fisherfaces (BELHUMEUR; HESPANHA; KRIEGMAN, 1997) também conhecido por LDA é uma derivação do PCA, pois utiliza combinações lineares de variáveis independentes para análise se determinada imagem pertence a um dos grupos de imagens. O conjunto de imagens de treinamento da face é composto de várias classes, em que cada classe representa um indivíduo, possibilitando com isso a identificação da classe a que determinada imagem de face pertence.

A ideia principal do Fisherfaces é encontrar um subespaço que projete os vetores das imagens de cada classe em um único grupo de representação no espaço de faces, de modo que esses grupos tenham a maior distância possível entre si. Logo os vetores resultantes são definidos como Fisherfaces. Este algoritmo encontra uma projeção que minimiza a variação intraclasses como também preserva a variação interclasses.

O Fisherfaces utiliza a matriz X para representar as c classes de imagens, conforme apresenta a Equação 51. E cada classe possui um conjunto M de imagens como podemos perceber na Equação 52.

$$X = [X_1, X_2, X_3, \dots, X_c] \quad (51)$$

$$X_i = [x_1, x_2, x_3, \dots, x_M] \quad (52)$$

Com isso, as matrizes S_B , S_W podem ser calculados de acordo com as equações 53 e 54 respectivamente.

$$S_B = \sum_{i=1}^c M_i (\mu_i - \mu)(\mu_i - \mu)' \quad (53)$$

$$S_W = \sum_{i=1}^c \sum_{x_j \in X_i} (x_j - \mu_i)(x_j - \mu_i)' \quad (54)$$

Nas equações 55 e 56 são apresentadas respectivamente a média geral μ e a média de cada classe μ_i .

$$\mu = \frac{1}{M} \sum_{i=1}^M x_i \quad (55)$$

$$\mu_i = \frac{1}{|X_i|} \sum_{x_j \in X_i} x_j \quad (56)$$

O algoritmo Fisherfaces clássico cria uma projeção Φ com iniciativas a maximizar os critérios de separabilidade entre as C classes.

$$\Phi_{opcional} = \underset{\Phi}{argmax} \frac{\Phi^T S_B \Phi}{\Phi^T S_W \Phi} \quad (57)$$

Entretanto essa solução apresentava-se consideravelmente custosa, mediante isso, Belhumeur, Hespanha e Kriegman (1997) apresentou uma solução com maior viabilidade computacional, resolvendo o problema com o auxílio dos autovalores:

$$S_B v_i = \lambda_i S_W \cdot v_i \quad (58)$$

$$S_W^{-1} S_B v_i = \lambda_i v_i \quad (59)$$

Todavia, surgiu um problema de modo que S_Φ é no máximo $(N - C)$ com N amostras e C classes. Levando essa justificativa para o contexto de reconhecimento de imagens, normalmente o número de imagens é muito menor que sua dimensão, de modo que a matriz S_Φ torna-se singular. Diante dessa questão uma nova solução foi proposta por Belhumeur, Hespanha e Kriegman (1997), em que foi aplicado o PCA sobre as amostras e os projetou no espaço $(N - C)$ dimensional, e logo em seguida os associou com o LDA, como pode ser visto nas equações 60 e 61.

$$\Phi_{pca} = \underset{\Phi}{argmax} |\Phi^T S_T \Phi| \text{ de modo que, } S_T = x - \mu \quad (60)$$

$$\Phi_{lda} = \underset{\Phi}{argmax} \frac{|\Phi^T \Phi_{pca}^T S_B \Phi_{pca} \Phi|}{|\Phi^T \Phi_{pca}^T S_W \Phi_{pca} \Phi|} \quad (61)$$

Logo a matriz de transformação Φ , projeta uma amostra no espaço (C-1) dimensional, esse processo pode ser visualizado pela Equação 62.

$$\Phi = \Phi_{lda}^T \Phi_{pca}^T \quad (62)$$

Na Figura 26 são apresentados 10 fisherfaces da base dados AR, sendo calculado o PCA com 95% de percentual de representatividade do conjunto.

Figura 26 – Exemplos de 10 fisherfaces da base de dados *AR*

Fonte: Jonas Mendonça Targino, 2019

4.4 Técnicas de reconstrução baseadas em modelo

As técnicas baseadas em modelo possuem como princípio básico a construção de um modelo computacional que represente o conjunto de faces, sem a necessidade de projetar a face parcialmente ocluída em um subespaço.

4.4.1 Representação Esparsa com Grafo de Poisson

Essa técnica proposta por Deng, Dai e Zhang (2011) é baseada em um grafo espectral para reconstrução de faces. Sendo composta de três processos principais: (i) aplicação da Representação Esparsa (técnica responsável por encontrar soluções a partir da resolução de sistemas lineares) na parte não ocluída, com iniciativa a descobrir quais indivíduos da base de treinamento possuem tal parte com maior grau de semelhança; (ii) mineração da imagem com maior valor de α ; e (iii) aplicação do Grafo de Poisson com formulação da matriz Laplaciana para descoberta dos pixels ocluídos.

A Representação Esparsa possui como principal objetivo identificar faces com similaridades perante um determinado conjunto, tomando para o contexto de faces ocluídas, dada uma face parcialmente ocluída é aplicada a Representação Esparsa como forma de analisar quais imagens de face presentes no conjunto de treinamento possuem maior semelhança. Essa semelhança é obtida por meio da combinação linear de todas as imagens de face e um vetor de erros no nível de pixel. Um dos primeiros trabalhos a utilizar SRC (do inglês: *Sparse Representation Classification*) para o reconhecimento de faces ocluídas foi proposto por Wright et al. (2009b).

Estudos realizados por Wright et al. (2009c), Yang et al. (2010), Zhang et al. (2010) indicam que SRC possibilita obter performances consideráveis perante a tarefa de reconhecimento de faces parcialmente ocluídas.

Na SRC, uma face ocluída parcialmente é vista como um sinal. E graças ao uso dela como sinal é possível obter sua SRC usando as imagens presentes no conjunto de treinamento. Dessa forma Υ é a imagem parcialmente ocluída representada como um sinal, de modo que a matriz de treinamento é da forma $\Gamma = [I_1, I_2, \dots, I_M]$, contendo M imagens. E $\mathbf{x}$ representa o vetor de coeficientes de correlação. Logo, na Equação 63 podemos perceber a estrutura de uma representação Esparsa.

$$\Upsilon = \alpha_1 I_1 + \alpha_2 I_2 + \dots + \alpha_M I_M = \Gamma \cdot \mathbf{x} \quad (63)$$

O vetor de coeficientes de correlação de forma $\mathbf{x} = [\alpha_1, \alpha_2, \dots, \alpha_M]$ possuem importância significativa para a imagem parcialmente ocluída, visto que o valor de α_i no intervalo $[0,1]$ representa a semelhança entre as imagens I_i e Υ . Logo, quanto maior o valor de α_i maior sua correlação com a imagem parcialmente ocluída. Vale a pena notar que o vetor $\mathbf{x}$ é esparso, ou seja, a maioria de seus valores são próximos de zero.

Segundo Wright et al. (2009c) com o vetor esparso apenas as imagens com maiores de α realizaram contribuições significativas perante a imagem parcialmente ocluída Υ . Dessa forma, no contexto de faces parcialmente ocluídas para obtermos valores de α com maiores valores de confiança devemos realizar a comparação dos pixels não ocluídos da imagem Υ com os pixels não ocluídos das imagens do conjunto de treinamento Γ .

Logo a SRC pode ser vista como uma Equação linear, da forma $\Upsilon = \Gamma \cdot \mathbf{x}$, sujeita ao problema otimização da Equação 64.

$$(l^0) : \hat{x}_0 = \operatorname{argmin} \|x\|_0 \quad x \mapsto \Gamma \cdot \mathbf{x} = \Upsilon \quad (64)$$

Mediante esse problema de otimização, o trabalho de Chen, Donoho e Saunders (2001) e Huang e Yang (2010) apresentam soluções que resolvem a Equação 65 em tempo polinomial. Entretanto neste trabalho adotou-se a formulação proposta por Huang e Yang (2010), a qual encontra-se disponível publicamente ¹.

$$(l^1) : \hat{x}_1 = \operatorname{argmin} \|x\|_1 \quad x \mapsto \Gamma \cdot \mathbf{x} = \Upsilon \quad (65)$$

Após o retorno dos α pela SRC são utilizadas as 20 imagens do conjunto de treinamento com maiores valores de α , mediante esse processo essas imagens retornadas são analisadas com base na métrica SSD (do inglês: *Sum Square Distance*) com finalidades a encontrar a imagem do conjunto de treinamento com maior semelhança dos pixels de borda da parte ocluída. Logo, é definida uma quantidade q de pixels de borda a serem adicionadas nas regiões de borda dos pixels ocluídos e com isso analisados os respectivos pixels nas imagens do conjunto de treinamento.

Um dos motivos de utilizar a métrica SSD para analisar a face com maior correlação com a imagem parcialmente ocluída é que a SRC necessita de outras métricas para dar suporte a sua classificação quando apresentada a tipos de dados com muita variação de ruído. Tal fato justifica-se que nem sempre utilizar o retorno com maior valor de α implica em realizar uma correta classificação, daí surgindo a necessidade de utilizar o SSD, tornando-se necessário visto que em muitos cenários práticos de reconhecimento facial, as amostras de treinamento de cada indivíduo são muitas vezes insuficientes, no caso extremo somente uma face de cada indivíduo pode estar disponível, dessa forma dando suporte a classificação realizada pela SRC.

Na Figura 27 ilustra-se a oclusão parcial, a região J significa os pixels de borda, nesse caso utilizando uma região de pixels de borda q igual a 10 pixels. Enquanto F representa a imagem ocluída. Logo para analisar qual das 20 imagens retornadas da SRC possuem maiores semelhanças dos pixels de borda são utilizados os pixels da região J .

¹ <http://faculty.ucmerced.edu/mhyang/papers/cvpr10a.pdf>

Figura 27 – Parte ocluída e aplicação das bordas na região ocluída, e por último a topologia do grafo de Poisson

Fonte: Jonas Mendonça Targino, 2019

A área J pode ser obtida com a aplicação de filtros morfológicos de erosão na máscara binária de oclusão. Nesse trabalho foi aplicada 10 vezes seguidas tal filtro morfológico na máscara de modo a possuir uma região J que circunda a área ocluída da imagem.

O cálculo do SSD pode ser resolvido com o auxílio da Equação 66, em que SR representa as 20 imagens retornadas pela representação esparsa.

$$SSD(x_0) = \sum_{x \in F} J(x)(F(x) - SR(x_0 - x))^2 \quad (66)$$

Logo o Grafo realiza a reconstrução da imagem parcialmente ocluída tomando por base a imagem retornada pela SRC com menor SSD, ou seja, com maior similaridade dos pixels de borda da oclusão.

O grafo de Poisson para reconstrução de faces proposto por Deng, Dai e Zhang (2011), possui como base a teoria de reconstrução da face via modelos gráficos de modo que cada pixel é representado por um nó no grafo, e os pixels não rotulados (ocluídos) são rotulados após a resolução de um sistema linear.

O grafo de Poisson possui como base um grafo $G = \{V, E\}$, com vértices $v \in V$ e arestas $e \in E \subseteq V \times V$, em que existe uma matriz binária W que indica a relação entre os nós.

Para reconstrução da imagem são utilizados dois grafos G_{no} e G_o de mesma topologia, de modo que G_{no} representa o grafo gerado pela imagem do treinamento com menor SSD, lembrando que esse grafo possui todos os seus nós rotulados, visto que não

apresenta oclusão, enquanto G_o é o grafo gerado pela imagem de consulta a qual possui alguns nós rotulados (pixels não ocluídos) e outros não rotulados (pixels ocluídos).

O objetivo desse grafo é tentar obter os rótulos faltantes em G_o para tentar reconstruir a imagem original. Para atingir tal objetivo deve-se realizar algumas operações com os dois grafos gerados, umas das primeiras operações a ser realizada é calcular a diferença dos dois grafos, podendo ser obtida pela forma $\Delta G = G_o - \kappa G_{no}$, de modo que κ é um parâmetro no intervalo $[0,1]$, responsável por controlar o grau de participação de G_{no} na tarefa de reconstrução dos nós não rotulados de G_o .

Tendo em vista o domínio Euclideano, a Equação Laplaciana pode ser visualizada com o auxílio da Equação 67, o operador de Laplace é definido por Δ^2 .

$$\Delta^2(G_o - \kappa G_{no}) = 0 \quad (67)$$

Entretanto, o Grafo de Poisson é implementado tendo como base o domínio gráfico que pode ser representado pela matriz Laplaciana $\mathbf{L}$ na teoria dos grafos espectrais, como demonstra a Equação 68.

$$\mathbf{L} = D - W \quad (68)$$

De modo que $D = \text{diag}(\sum_j W_{ij})$ em que D é chamado de grau da matriz na teoria espectral dos grafos e W é a matriz de pesos com entradas W_{ij} , W representa a máscara de oclusão da imagem de consulta como uma matriz simétrica que representa a correlação entre os nós no grafo, contendo o valor 1 nos pixels não ocluídos e 0 nos pixels ocluídos. Logo a Equação final para o cálculo de G_o pode ser escrita na Equação 69.

$$\mathbf{L}G_o = \kappa \mathbf{L}G_{no} \quad (69)$$

A Figura 28 ilustra detalhadamente o processo necessário para realizar a reconstrução com Grafo de Poisson.

Figura 28 – Estrutura da técnica SRC com Grafo de Poisson

Fonte: Jonas Mendonça Targino, 2019

Logo para descobrirmos os pixels ocluídos temos que resolver o sistema que pode ser decomposto com o auxílio da formulação abaixo.

$$\begin{aligned}
 L &= D - W \\
 L &= \text{diag} \left[\sum_j W_{ij} \right] - W \\
 &= \begin{bmatrix} \sum_j W_{1j} & & & \\ & \sum_j W_{2j} & & \\ & & \ddots & \\ & & & \sum_j W_{nj} \end{bmatrix} - W
 \end{aligned}$$

Dessa maneira a matriz Laplaciana do grafo com 4 conexões é da forma:

$$\mathbf{L}G_{no} = \begin{bmatrix} 4 & -1 & -1 & -1 & -1 & \dots & 0 \\ -1 & 4 & -1 & -1 & -1 & \dots & 0 \\ -1 & -1 & 4 & -1 & -1 & \dots & 0 \\ -1 & -1 & -1 & 4 & -1 & \dots & 0 \\ \vdots & \vdots & \ddots & & \ddots & & \\ 0 & \dots & -1 & -1 & -1 & & 4 \end{bmatrix} \cdot \begin{bmatrix} G_{no_1} \\ G_{no_2} \\ G_{no_3} \\ \vdots \\ G_{no_{(n-1)}} \\ G_{no_n} \end{bmatrix}.$$

Com isso, chegamos a resolução do sistema geral, pela forma:

$$\mathbf{L}G_{no} = \kappa \mathbf{L}Go$$

Logo após a descoberta do sistema temos que apenas substituir os pixels ocluídos na imagem parcialmente ocluída pelos pixels retornados pela resolução do sistema linear da matriz laplaciana.

4.5 Considerações finais do capítulo

Neste capítulo foram apresentadas as técnicas para detecção e reconstrução das oclusões parciais, de modo que foram implementadas três técnicas para detecção da oclusão, dessas três a que apresentou melhores segmentações da área ocluída foi a técnica BMA. Enquanto das técnicas de reconstrução foram apresentadas oito técnicas, sete baseadas em subespaço e uma baseada em modelo.

5 Extração de características e classificação

Para que o sistema biométrico possa realizar a identificação dos indivíduos é necessário que existam técnicas para extração das características e logo em seguida suas respectivas classificações. Deste modo neste capítulo são apresentadas as técnicas para extração e classificação das características utilizadas neste trabalho.

Como estratégia de extração de características foi utilizada a Transformada Wavelet (TW), já na tarefa de classificação aplicou-se os classificadores K-vizinhos mais próximos (do inglês: *K Nearest Neighbors* - KNN), Máquina de Aprendizado Extremo (do inglês: *Extreme Learning Machine* - ELM) e Máquinas de Vetores de Suporte (do inglês: *Support Vector Machine* - SVM). Os quais estão descritos com mais detalhes nas seções abaixo.

5.1 Transformada Wavelet

Para extração das características, foi aplicada a TW (MALLAT, 1989) que é considerada uma técnica de processamento de sinal que atua tanto no domínio da frequência como no domínio do tempo diferentemente da Transformada de Fourier que atua apenas no domínio da frequência. É uma técnica muito utilizada para extração de características seja de um sinal por meio de decomposições 1D ou de uma imagem por meio de decomposições 2D. Aplicando as decomposições seja em um sinal ou uma imagem são gerados alguns elementos chamados coeficientes que podem ser de baixa e alta frequência e que representam, respectivamente, detalhes e aproximações dos dados originais.

Essa abordagem utiliza um conjunto de filtros de suavização de imagem, sendo um filtro passa-baixa g , que representa uma aproximação do sinal original e um filtro passa-alta h , representando os detalhes. Como as imagens são dados bidimensionais, após a decomposição Wavelet 2D são geradas quatro subimagens, cada uma delas de dimensão $(\frac{n}{2} \times \frac{n}{2})$. Alguns autores chamam de *down-sampling* o processo de diminuição das dimensões da imagem, esse processo sendo representado pelas setas para baixo conforme a Figura 29. Seguindo esse contexto, supondo que a imagem a ser extraída a característica possui dimensão (256×256) pixels, ao final as subimagens geradas possuem dimensão (128×128) pixels, sendo originadas por meio da aplicação dos filtros passa-baixa e passa-alta nas linhas e colunas da imagem.

Na Figura 29 é apresentada uma rápida ilustração dos passos de decomposição da Wavelet 2D com as quatro subimagens sendo elas: (i) LL (aproximação); (ii) HL (detalhes horizontais); (iii) LH (detalhes verticais); e (iv) HH (detalhes diagonais). De tal modo que a imagem LL representa apenas uma aproximação da imagem original.

Figura 29 – Estrutura de uma Transformada Wavelet

Fonte: Jonas Mendonça Targino, 2019

Na Figura 30 é apresentada um exemplo de subimagens geradas por meio da Transformada Wavelet 2D (LL, HL, LH e HH), ao final esse conjunto de coeficientes pode ser utilizado para representar a imagem original. Pode-se utilizar os coeficientes de aproximação LL, nos mais diversos níveis, entretanto no trabalho de (COSTA, 2011), o mesmo ao utilizar imagens com dimensões (256×256) obteve menor dimensão dos dados e boa representatividade do conjunto, não influenciando muito na acurácia de reconhecimento ao utilizar os níveis de decomposição 1 e 2.

Costuma-se utilizar os componentes da imagem LL do nível 3, que representa uma aproximação da imagem original e apresenta menor dimensão e boa representatividade, como relatado no trabalho de Costa (2011).

Figura 30 – Imagens obtidas após a decomposição Wavelet 2D

Fonte: Jonas Mendonça Targino, 2019. Imagem de face obtida da base Yale (GEORGHIADES; BELHUMEUR; KRIEGMAN, 1997)

5.2 *K-Vizinhos mais próximos*

O KNN é um algoritmo proposto a mais de seis décadas, sendo bastante utilizado e estudado para a tarefa de reconhecimento de padrões. De maneira que seu núcleo de funcionamento está em descobrir o vizinho mais próximo de um determinado ponto. Podendo encontrar os K vizinhos mais próximos de um ponto de consulta, em vez de utilizar apenas o primeiro vizinho mais próximo.

A ideia geral do KNN é classificar um dado elemento a partir da análise das respectivas classes dos K vizinhos mais próximos pertencentes ao conjunto de treinamento. Essa técnica calcula a distância do ponto de consulta para cada elemento do conjunto de treinamento. Após esse cálculo, todas as distâncias são ordenadas em ordem crescente do elemento mais próximo ao mais distante.

Após os elementos ordenados, são selecionados os K primeiros, os quais são utilizados para a tarefa de classificação. Exemplo: 1-NN utiliza-se o $K = 1$, ou seja, utilizamos o primeiro elemento do conjunto de treinamento, aquele que apresenta menor distância. Já o 6-NN vai utilizar os seis vizinhos mais próximos, e com base nos votos majoritários do seis

vizinhos mais próximos infere-se a classe do elemento de consulta. É possível visualizar na Figura 31 um exemplo de classificação com K-NN, de modo que $K = 6$ realiza a classificação da como classe B (azul), ou seja, a maioria (quatro) dos votos.

Figura 31 – Exemplo de classificação do K-NN com duas classes e $K = 6$

Fonte: Jonas Mendonça Targino, 2019

A literatura apresenta muitas aplicações usando KNN, como o diagnóstico de câncer de mama (SARKAR; LEONG, 2000), a classificação de texto (YU; YU, 2007) e (HAN; KARYPIS; KUMAR, 2001), reconhecimento de emoção (CHENG; LIU; QIU, 2008), identificação de falante (KACUR; VARGIC; MULINKA, 2011), entre muitos outros.

Uma das principais fraquezas do classificador KNN é que todas as amostras de treinamento devem ser armazenadas na memória e, para realizar a classificação, é necessário o cálculo da distância da amostra de teste para todas as amostras de treino. À medida que o número de amostras no conjunto de treinamento aumenta, armazenar todos os seus valores na memória do computador pode não ser viável e também o procedimento de classificação pode levar muito tempo devido ao cálculo das distâncias.

5.3 Máquina de aprendizado extremo

Máquina de Aprendizado Extremo (do inglês: *Extreme Machine Learning* - ELM) é um algoritmo de classificação proposto por (HUANG; ZHU; SIEW, 2006) e (FENG et al., 2009). A ELM é uma rede neural artificial (RNA) com uma única camada oculta, essa estratégia vem alcançando sucesso no contexto de classificação e regressão.

A ELM possui o mesmo princípio de funcionamento de uma RNA, diferenciando-se da MLP e RBF por sua metodologia de treinamento que não é baseada em gradientes. Isso deve-se ao fato que a ELM atualiza apenas os pesos da camada escondida. Já os pesos da camada de entrada são escolhidos aleatoriamente e fixados, isso permite a essa estratégia escapar das principais deficiências do algoritmo de treinamento *backpropagation*. Possibilitando velocidade de aprendizado significativamente rápida, quando comparada a redes neurais MLP e RBF, assim como também proporciona menor intervenção humana do que outros algoritmos. Outro ponto é a facilidade e rapidez na implementação quando comparada a implementação de outros classificadores tradicionais.

A ELM pode determinar analiticamente todos os parâmetros de uma rede neural MLP em vez de ajustar parâmetros iterativamente. Assim, podendo superar algumas das dificuldades do método baseado em gradientes e da maioria dos outros métodos de aprendizagem. O trabalho de (HUANG; ZHU; SIEW, 2006) também mostra que a ELM tende alcançar melhores resultados de generalização do que técnicas de classificação como SVM. Outro fator importante da ELM é sua baixa sensibilidade aos parâmetros especificados pelo usuário. Na Figura 32 é possível visualizar a estrutura de uma ELM.

Figura 32 – Estrutura de uma Rede Neural ELM

Fonte: Jonas Mendonça Targino, 2019

No treinamento da ELM a matriz $\mathbf{W}$ (pesos da camada de entrada) é gerada de maneira aleatória e é inalterada. Portanto, o objetivo do treinamento da ELM é encontrar a matriz de pesos β , que são os pesos da camada oculta, baseado na matriz de saída $\mathbf{Y}$ e na matriz de pesos aleatórios $\mathbf{W}$, por meio da resolução de um sistema linear.

Com essa finalidade, a primeira ação é determinar $\mathbf{H}$, que é a matriz que contém a função de ativação (podendo ser sigmóide, tangente hiperbólica, e etc.) dos neurônios da camada oculta. Portanto, a matriz $\mathbf{H}$ armazena o resultado de todos os neurônios da camada oculta obtidos a partir da multiplicação entre $\mathbf{X}$ e $\mathbf{W}$. Após determinada a matriz $\mathbf{H}$, para se obter os pesos da matriz β deve ser solucionado o sistema linear presente na equação 70.

$$H = f_{ativ}(X \cdot W) \Rightarrow H\beta = Y \Rightarrow \mathbf{B} = pinv(H) \cdot Y \quad (70)$$

Em que f_{ativ} é a função de ativação e $pinv$ é pseudo inversa da matriz H .

5.4 Máquina de vetores suporte

A Máquina de Vetores Suporte (do inglês: *support vector machine* - SVM)(CORTES; VAPNIK, 1995) funciona da seguinte forma: dado um conjunto de dados de treinamento composto de N amostras $\{x_i, y_i\}_{i=1}^N$ com entrada $x_i \in \mathcal{R}^n$ e saída $y_i \in \pm 1$, o classificador SVM visa construir uma superfície de decisão da forma $sign[f(x; w)]$, em que $f(x; w) = w^T \phi(x) + b$ é uma aproximação da função de mapeamento y , $w \in \mathcal{R}^m$ e $\phi: \mathcal{R}^n \rightarrow \mathcal{R}^m$ é uma função que mapeia a entrada para um espaço de dimensão superior. Os parâmetros w e b podem ser obtidos por meio do seguinte problema de otimização (VAPNIK, 1995):

$$\min_{w, b, \xi} \Phi(w, b, \xi) = \frac{1}{2}(w^T w) + C \sum_{i=1}^N \xi_i, \quad (71)$$

sujeito a $y_i[w^T \phi(x_i) + b] \geq 1 - \xi_i$, $\xi_i \geq 0$, $i = 1, \dots, N$, em que C é um parâmetro de ajuste que indica a importância relativa da complexidade do modelo quando comparado ao erro de treinamento e ξ_i é o erro de treinamento para a amostra i . Por simplicidade, o problema apresentado na equação (71) geralmente é convertido em um problema equivalente definido em um espaço duplo, construindo o seguinte Lagrangiano (VAPNIK, 1995): $L(w, b, \xi, \beta, \gamma)$.

$$\frac{1}{2}w^T w + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \beta_i \{ [w^T \phi(x_i) + b] y_i - 1 + \xi_i \} - \sum_{i=1}^N \gamma_i \xi_i \quad (72)$$

em que $\beta_i \geq 0$, $\gamma_i \geq 0$, ($i = 1, \dots, N$) são multiplicadores de Lagrange. Em tal informação, um determinado tipo de função, conhecido como *kernel*, é empregado (SCHOLKOPF; SMOLA, 2001). Deve seguir a restrição imposta pelo Teorema de Mercer e fornece um

cálculo implícito de um passo do produto entre $\phi(x_i)$ e $\phi(x_j)$: $K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$. Os resultados do SVM discutidos no capítulo 8 foram obtidos com o Kernel RBF da forma: $K(x_i, x_j) = \exp\left(-\frac{(x_i - x_j)^T(x_i - x_j)}{2\sigma^2}\right)$, em que σ^2 indica a variância a ser definida pelo usuário. Usando o Kernel, $f(x; w)$ podem ser reescritos como $f(x; w) = \sum_{i=1}^N \beta_i y_i K(x, x_i) + b$.

Para as amostras de treino ao longo do limite de decisão, os correspondentes α_i são maiores do que zero, conforme estabelecido pelo teorema de Karush-Kuhn-Tucker. Essas amostras são conhecidas como vetores de suporte. O número de vetores de suporte geralmente é muito menor que N , sendo proporcional ao erro de generalização do classificador. O vetor de teste x em R^m é atribuído a uma determinada classe de acordo com $f(x) = \text{sign}[\mathbf{w}^T \phi(\mathbf{x}) + b] = \text{sign}(\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b)$. Podemos visualizar o problema de classificação binário por meio da Figura 33, em que temos duas classes, a classe de triângulos (em vermelho) e classe círculo (em amarelo), e a ideia principal do SVM é maximizar a margem de separação entre as duas classes, por meio dos vetores de suporte.

Figura 33 – Problema de classificação binário com SVM

Fonte: Jonas Mendonça Targino, 2019

5.5 Considerações finais do capítulo

Existe uma quantidade considerável de classificadores e extratores presentes na literatura, entretanto neste trabalho foi utilizada a Transformada Wavelet como extrator de características, enquanto como classificadores utilizou-se K-vizinhos mais próximos, Máquina de Aprendizado Extremo e Máquinas de Vetores de Suporte.

6 Abordagem Proposta

Este capítulo possui como objetivo principal apresentar a proposta de pesquisa na qual essa dissertação se embasou, como também a metodologia utilizada para o desenvolvimento da mesma e alguns resultados esperados com este trabalho.

6.1 Proposta

A motivação para desenvolvimento dessa pesquisa surge de estudos promissores na área de biometria, alegando-se que a sociedade apresenta necessidades cada vez maiores de tecnologias que favoreçam segurança e bem-estar de toda a população, a partir dessa justificativa, estudos nesse âmbito apresentam viabilidade de aplicações nos mais diversos setores. Essa prerrogativa de detecção de oclusões parciais em imagens da face, surge a partir da demanda de identificação em ambientes que não necessitem da cooperação do usuário para a coleta de dados.

O foco deste trabalho nessa área surge com iniciativas a reverter as baixas taxas de reconhecimento em ambientes dessa natureza, pela justificativa de que em cenários como esses, que a pessoa não possui a intenção de colaborar para a sua identificação, lidamos com inúmeros tipos de imagens, algumas identificáveis automaticamente, outras não, o foco deste estudo é nas imagens faciais que não são identificáveis automaticamente devido a presença das oclusões.

Há várias técnicas propostas na literatura para detecção e reconstrução de oclusões parciais em imagens de face. No entanto, não há estudos que mencionem quais técnicas são mais adequadas para determinado tipo de oclusão sobre tal ambiente, visto que existem inúmeros tipos de oclusões e ambientes. Logo, pretende-se avaliar o impacto dessas técnicas na detecção e reconstrução de diferentes tipos de oclusões para o reconhecimento biométrico. Como resultado deste estudo, espera-se identificar os principais prós e contras dessas técnicas como também eventuais limitações, e com isso sugerir qual a técnica mais adequada para os mais diversos tipos de oclusões.

A presente proposta apresenta um grau significativo de contribuição em termos gerais, abrangendo o estado de arte, suas técnicas, algoritmos para detecção e reconstrução de oclusões parciais e condições de viabilidade de aplicação, levando em conta as variações

de iluminação, pose, expressão e oclusão. Os resultados obtidos com esta pesquisa serão de grande valia para pesquisadores que trabalham nesse âmbito, como também iniciantes que almejam conhecimento holístico do estado de arte para desenvolvimento de futuras pesquisas, de modo a produzir um conhecimento significativo e enriquecimento para o campo da biometria e para os pesquisadores que tentam colaborar no reconhecimento facial independente das condições de coleta dos dados.

Em suma, um estudo comparativo das técnicas para detecção de oclusões parciais e reconstrução de faces pode contribuir significativamente para a área de reconhecimento facial em ambientes não controlados, visto que a comparação envolve análise e síntese de semelhanças, diferenças e padrões entre as técnicas. De acordo com Collier (1993) o estudo comparativo tem elevado grau de contribuição científico, dado que ele sugere similaridades e contrastes entre os casos, podendo participar da descoberta indutiva de novas hipóteses e posteriormente construção de novas teorias.

Mediante todo o contexto na Figura, 34 é apresentado um esquema contendo todo um escopo deste trabalho. Sendo possível visualizar todos os passos necessários para atingir tal objetivo.

Figura 34 – Esquema proposto nesta dissertação

Fonte: Jonas Mendonça Targino, 2019

6.2 Proposição de três algoritmos

Durante a implementação e experimentos das técnicas de reconstrução de faces percebeu-se alguns pontos fortes e fracos de cada técnica. Desta forma, paralelamente ao estudo comparativo foram desenvolvidas três técnicas de reconstrução, em que duas delas apresentaram os melhores resultados perante o conjunto de técnicas comparadas neste trabalho. Dessas três técnicas, duas são baseadas em modelo e uma baseada em subespaço. As quais são apresentadas com mais detalhes nas próximas subseções.

6.2.1 Representação Esparsa com Fast Recursive PCA

Essa técnica baseada em subespaço possui um diferencial frente as demais técnicas de mesma natureza, sendo uma análise de representação e classificação da imagem de consulta, além de reduzir o número de indivíduos para geração do espaço de faces.

Essa técnica possui como base três etapas, sendo elas: (i) aplicação da representação esparsa; (ii) mineração das imagens obtidas com a SRC; (iii) reconstrução com a técnica *Fast Recursive PCA*.

Na primeira etapa desse algoritmo é utilizada a SRC com a formulação proposta por Huang e Yang (2010) tomando por base os pixels não ocluídos da imagem parcialmente ocluída, de modo que são analisados os mesmos pixels do conjunto de treinamento. Após esse processo são selecionadas as 20 melhores imagens com maior valor do coeficiente de correlação após o retorno da SRC.

Para o cálculo da SRC adotou-se que Υ é a imagem parcialmente ocluída representada como um sinal, de modo que a matriz de treinamento é da forma $\Gamma = [I_1, I_2, \dots, I_M]$, contendo M imagens. E $\mathbf{x}$ representa o vetor de coeficientes de correlação. Logo, na Equação 73 é apresentada a estrutura da SRC.

$$y = \alpha_1 I_1 + \alpha_2 I_2 + \dots + \alpha_M I_M = \Gamma \cdot \mathbf{x} \quad (73)$$

O vetor de coeficientes de correlação de forma $\mathbf{x} = [\alpha_1, \alpha_2, \dots, \alpha_M]$ possui importância significativa para a imagem parcialmente ocluída, visto que o valor de α_i no intervalo $[0,1]$ representa a semelhança entre as imagens I_i e y . Logo, quanto maior o valor

de α_i maior sua correlação com a imagem parcialmente ocluída. Dessa forma o vetor $\mathbf{x}$ é esparso, ou seja, a maioria de seus valores são próximos de zero.

Dessa maneira de acordo com Wright et al. (2009c) apenas as imagens correspondentes aos maiores valores dos coeficientes de correlação apresentam maiores semelhanças perante a imagem de consulta Υ . Dessa forma, no contexto de faces parcialmente ocluídas para obtermos valores de alfa com maiores valores de confiança devemos realizar a comparação dos pixels não ocluídos da imagem Υ com os pixels não ocluídos das imagens do conjunto de treinamento Γ .

Logo a SRC pode ser vista como uma equação linear, da forma $\Upsilon = \Gamma \cdot x$, sujeita ao problema otimização da Equação 74 .

$$(l^1) : \hat{x}_1 = \operatorname{argmin} \|x\|_1 \quad x \mapsto \Gamma \cdot x = \Upsilon \quad (74)$$

Após as 20 melhores imagens selecionadas de acordo com seu coeficiente de correlação, foi utilizada uma zona de pixels de borda da oclusão. Em que essa zona de pixels abrangia um total de 10 pixels, sendo demarcada a partir da aplicação do filtro morfológico de erosão na máscara de oclusão 10 vezes consecutivas.

Enquanto que na etapa 2 para mineração da face com maior semelhança advinda da representação esparsa foi utilizada a técnica SSIM proposta por Wang et al. (2004) para análise das similaridades entre os pixels de borda da imagem de consulta e os respectivos pixels das 20 imagens de treinamento providas do retorno da SRC.

Para a reconstrução da face foi utilizada a técnica *Fast Recursive PCA* proposta por Wang e Tao (2007), também apresentada neste trabalho.

Na terceira e última etapa é gerado o espaço de faces com todas as imagens de face de três indivíduos, sendo eles:

- o primeiro indivíduo sendo obtido com o maior valor de coeficiente de correlação retornado pela SRC;
- o segundo indivíduo é o que mais se repetiu perante os 20 melhores retornados com a SRC;
- E o terceiro indivíduo é proveniente da etapa de mineração dos dados, sendo o que apresentou maior SSIM dos pixels de borda da oclusão com os respectivos pixels das imagens de treinamento.

Na Figura 35 é possível visualizar a estrutura dessa nova técnica, assim como também a sua respectiva sequência de passos para a reconstrução.

Figura 35 – Estrutura da técnica SRC com *Fast Recursive PCA*

Fonte: Jonas Mendonça Targino, 2019

6.2.2 Representação Esparsa com Grafo Laplaciano

Essa técnica aqui proposta possui como princípio geral aplicação da Representação Esparsa para classificação das faces de treinamento com maiores semelhança com a imagem parcialmente ocluída para logo em seguida realizar a reconstrução com grafo Laplaciano.

Essa técnica é constituída de três passos sendo eles: (i) aplicação da representação Esparsa com a formulação proposta por Huang e Yang (2010) no conjunto de imagens de treinamento; (ii) mineração da imagem com maior coeficiente de correlação; (iii) reconstrução com grafo Laplaciano.

O primeiro passo dessa técnica possui como objetivo realizar a classificação da face de treinamento com maior proximidade da face parcialmente ocluída. Como entrada para a SRC foram utilizados os pixels não ocluídos da imagem ocluída, dessa forma, a SRC buscava as faces com maiores coeficientes de correlação dos respectivos pixels do conjunto de treinamento. Dessa forma foram selecionadas as 20 imagens do conjunto de treinamento com maiores coeficientes de correlação.

Após o retorno das 20 imagens de face com maiores coeficientes de correlação utilizou-se os pixels vizinhos da oclusão de modo a analisar a similaridade dos pixels vizinhos não ocluídos da imagem ocluída com os respectivos pixels das 20 imagens retornadas. Para geração da borda de oclusão foram utilizados 10 operadores morfológicos de erosão (resultando em uma borda de oclusão com 10 pixels) na máscara de oclusão de modo a identificar os pixels de borda.

Após os pixels de borda selecionados da imagem de consulta e das 20 imagens de treinamento, foi utilizado o algoritmo KNN com distância Euclidiana de modo a identificar qual a face que possui as regiões de borda dos pixels ocluídos com menor distância (ou seja, com maior semelhança dos pixels). Dessa forma a distância do KNN é calculada tomando por base a Equação 75. Em que J_{I_i} e J_y representam respectivamente os pixels de borda J da imagem I_i e da imagem de consulta.

$$Dist = \sqrt{\sum_{i=1}^n (J_{I_i} - J_y)^2} \quad (75)$$

Nesse algoritmo, a topologia de conexão de um nó é alterada para os k vizinhos mais próximos, neste caso o k possui valor 10. A Figura 36 ilustra a área J dos pixels de borda, como também a topologia do grafo Laplaciano utilizado nesse trabalho, em que o ponto vermelho representa o pixel corrente e todos os outros 10 pontos representam seus 10 pixels vizinhos.

Figura 36 – Topologia do grafo Laplaciano

Fonte: Jonas Mendonça Targino, 2019

A formulação matemática dessa técnica difere-se da técnica SRC com grafo de Poisson apresentada na subseção 4.4.1 e proposta por Deng, Dai e Zhang (2011) por utilizar KNN em vez de SSD nos pixels de borda J , também por utilizar uma nova

topologia com 10 conexões por pixel, e além do mais sua matriz Laplaciana também apresenta modificações quanto ao número de conexões por pixel.

Logo para descobrirmos os pixels que irão ser substituídos pelos pixels ocluídos temos que resolver o sistema que pode ser decomposto com o auxílio da formulação abaixo. É importante notarmos a diferença da matriz Laplaciana na topologia do grafo Laplaciano.

$$\begin{aligned}
 L &= D - W \\
 L &= \text{diag} \left[\sum_j W_{ij} \right] - W \\
 &= \begin{bmatrix} \sum_j W_{1j} & & & & \\ & \sum_j W_{2j} & & & \\ & & \ddots & & \\ & & & \ddots & \\ & & & & \sum_j W_{nj} \end{bmatrix} - W
 \end{aligned}$$

Dessa maneira a matriz Laplaciana do grafo com 10 conexões é da forma:

$$\mathbf{L}G_{no} = \begin{bmatrix} 10 & -1 & -1 & -1 & -1 & \dots 0 \\ -1 & 10 & -1 & -1 & -1 & \dots 0 \\ -1 & -1 & 10 & -1 & -1 & \dots 0 \\ -1 & -1 & -1 & 10 & -1 & \dots 0 \\ \vdots & \vdots & \ddots & & \ddots & \\ 0 & \dots & -1 & -1 & -1 & 10 \end{bmatrix} \cdot \begin{bmatrix} G_{no_1} \\ G_{no_2} \\ G_{no_3} \\ \vdots \\ G_{no_{(n-1)}} \\ G_{no_n} \end{bmatrix}$$

Com isso, chegamos a resolução do sistema geral, pela forma:

$$\mathbf{L}G_{no} = \kappa \mathbf{L}Go$$

Logo após a descoberta do sistema temos que apenas substituir os pixels ocluídos na imagem parcialmente ocluída pelos pixels retornados pela resolução do sistema linear da matriz laplaciana.

Dessa forma no terceiro e último passo, a imagem correspondente aos pixels de borda com menor distância, ou seja, a imagem G_{no} passada para a reconstrução com grafo Laplaciano. A Figura 37 ilustra a estrutura da técnica bem como os passos necessários para realizar a reconstrução.

Figura 37 – Estrutura da técnica SRC com Grafo Laplaciano

Fonte: Jonas Mendonça Targino, 2019

6.2.3 Similaridade Estrutural com grafo Laplaciano

Uma grande quantidade de técnicas para classificação e identificação de faces vem sendo dispostas na literatura, entretanto, essas técnicas apresentam queda de desempenho quando apresentadas a ambientes não controlados, um dos maiores fatores que impactam essa queda é a oclusão. Entretanto manipular a oclusão não é uma tarefa simples, com isso, inúmeras iniciativas vem sendo apresentadas com iniciativas a realizar uma classificação do indivíduo apenas utilizando a parte não ocluída, algumas dessas iniciativas são os trabalhos de Deng, Dai e Zhang (2011), Yang et al. (2014) e Wright et al. (2009c) que utilizam SRC. Uma das desvantagens dessas técnicas é que ao lidar com imagens com variações de oclusões e iluminação há queda considerável de performance, sem contar que a SRC em imagens com tais variações necessita de outras técnicas (como SSD, KNN e SSIM) de modo a complementar seu resultado, em alguns trabalhos são utilizadas técnicas baseadas em distância para tentar encontrar as faces do conjunto de treinamento com maiores similaridades.

Essa técnica também construída durante a elaboração deste trabalho, sendo intitulada de SSIMGL. Constitui-se de três passos principais que são: (i) redução do tamanho de todas as imagens de modo a reduzir a complexidade do problema; (ii) aplicação da técnica de validação de imagens Similaridade Estrutural para classificação da parte não

ocluída perante a face parcialmente ocluída; *(iii)* inserção da imagem no grafo Laplaciano no seu tamanho original; *(iv)* aplicação do Grafo Laplaciano para reconstrução da face.

O primeiro passo dessa técnica possui como base redução de todas as imagens para a dimensão (32×32) de modo a reduzir o tempo e a complexidade computacional e consequentemente manipular um conjunto de imagens com menores dimensões. Essa redução da dimensão foi tomada com base em testes realizados, em que visualizou-se que com essa dimensão era possível detectar a parte ocluída de maneira satisfatória e aplicar a similaridade estrutural na parte não ocluída com considerável performance da técnica.

Enquanto a segunda etapa dessa técnica possui como base aplicação da análise da similaridade estrutural (WANG et al., 2004) dos pixels não ocluídos da imagem de consulta, com os respectivos pixels das imagens do conjunto de treinamento. A métrica SSIM está descrita com mais detalhes na subseção 3.5.2. Nessa etapa o mais importante dela é verificar quais das imagens do conjunto de treinamento possui maior SSIM ao realizar a comparação dos pixels não ocluídos da imagem de consulta com os respectivos pixels da imagem do treinamento.

A métrica SSIM foi escolhida visto que segundo Thung e Raveendran (2009) essa métrica atua de forma a simular o grau de percepção humana, se ajustando independente do ambiente de coleta da imagem. Portanto, essa métrica possibilita consideráveis resultados independente do ambiente de coleta.

Enquanto o terceiro passo tem como objetivo utilizar a imagem com maior SSIM no seu tamanho original (128×128) fornecendo melhor qualidade de reconstrução. Dado que reduzir a dimensão das imagens no primeiro passo é interessante para reduzir o tempo computacional utilizado.

E o último passo e não menos importante dessa técnica é a reconstrução da imagem de consulta com grafo Laplaciano. A reconstrução com grafo Laplaciano possui funcionamento similar ao grafo Laplaciano descrito matematicamente na subseção 4.4.1, diferenciando-se por utilizar os 10 nós vizinhos para geração do grafo, enquanto no grafo de Poisson são utilizados apenas os 4 vizinhos (acima, abaixo, esquerda e direita), dessa forma, paralelamente alterando a matriz Laplaciana seguindo o modelo matemático do grafo Laplaciano apresentado na subseção 6.2.2. O funcionamento e estrutura da técnica SSIMGL é apresentado na Figura 38.

Figura 38 – Estrutura da técnica SSIMGL

Fonte: Jonas Mendonça Targino, 2019

6.3 Aplicação no meio científico deste trabalho

A comparação e proposição de novas técnicas de detecção e reconstrução de oclusões parciais em imagens de face pode produzir novos caminhos e direcionamentos para os pesquisadores da área, dando suporte para a pesquisa e direcionamento holístico do tema de pesquisa e suas conseqüentes limitações. Além disso, este documento contém uma descrição detalhada e unificada de cada técnica de detecção e reconstrução de imagens de face parcialmente ocluídas. Além de disponibilizar os códigos de todas as técnicas bem como ilustrações durante a descrição da técnica que ajudam a compreender o funcionamento da mesma.

Acreditamos que este trabalho acarretará em uma contribuição significativa para a área de reconhecimento biométrico, mais especificamente ao reconhecimento facial em ambientes não controlados. Uma outra contribuição deste trabalho é possibilitar subsídios junto à comunidade científica na produção e disponibilização das técnicas de detecção e reconstrução de oclusões parciais em imagens da face, e conseqüentemente disponibilização das formulações matemáticas de cada algoritmo e seu respectivo código fonte. Objetivando futuras replicações pelos pesquisadores da área e leigos que possuem interesse em se aprofundar no assunto.

7 Materiais e métodos

Este capítulo possui como finalidade apresentar como foram conduzidos os experimentos realizados nessa pesquisa. Também apresentando as bases de dados utilizadas nos experimentos, suas especificidades e alterações realizadas.

7.1 Bases de dados

Neste trabalho foram utilizadas as seguintes bases disponibilizadas publicamente na literatura:

- (i) **AR**¹, disponibilizada por Martinez (1998) criada pela Universidade Autônoma de Barcelona, essa base possui 2600 imagens de face frontais de 100 indivíduos (50 homens e 50 mulheres). De modo que para cada indivíduo são coletadas 26 fotos, sujeitas a 13 variações de condições, a saber: diferentes expressões faciais, condições de iluminação e variações de oclusão (com óculos de sol e cachecol).
- (ii) **Yale**², disponibilizada por Georgiades, Belhumeur e Kriegman (1997) criada pela Universidade da Califórnia, essa base de dados contém 165 imagens frontais de 15 pessoas, com 11 imagens de face por pessoa. Além de apresentar variações de iluminação, expressão e oclusão (baixos níveis de oclusão ocasionados por óculos de grau).

A primeira base é composta de 1400 imagens não ocluídas e 1200 ocluídas. Enquanto a segunda base possui 150 imagens não ocluídas e 15 ocluídas com óculos de grau, a partir destas 15 foram geradas 30 novas imagens (conforme a seção 7.2), somando no total 180 imagens. Na Figura 39 são apresentados exemplos de imagens das duas bases de dados. Enquanto na Figura 40 é possível visualizar as 13 variações das condições do ambiente presente na base AR.

¹ <http://www2.ece.ohio-state.edu/~aleix/ARdatabase.html>

² <http://vision.ucsd.edu/content/yale-face-database>

Figura 39 – Exemplos de imagens das bases de dados AR e Yale

Fonte: AR (MARTINEZ, 1998) e Yale (GEORGHIADIS; BELHUMEUR; KRIEGMAN, 1997)

Figura 40 – Exemplos de variações das imagens capturadas presentes na base de dados AR

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

7.2 Pré-processamento das imagens

Primeiramente, todas as imagens de face foram convertidas para escala de cinza. Em seguida foi aplicado o algoritmo Viola-Jones (VIOLA; JONES, 2004) para segmentar a região de interesse, e assim reduzir a influência de ruídos (como por exemplo o fundo da imagem) que podem afetar o processo de classificação. Logo após esse processo, as imagens foram redimensionadas para a dimensão (128 x 128) pixels. A Figura 41 ilustra o processo de aplicação do algoritmo Viola-Jones em duas imagens de face.

Figura 41 – Detecção da face utilizando o algoritmo Viola-Jones

Fonte: Jonas Mendonça Targino, 2019. Imagens de faces obtidas da base AR (MARTINEZ, 1998)

Após a detecção da face, percebeu-se que as imagens de oclusões (óculos de grau) presentes na base Yale eram muito simples, podendo influenciar na análise comparativa e produzir resultados não realísticos. Mediante este problema, manipulou-se as 15 imagens presentes na base Yale com oclusões e para cada imagem foram geradas duas outras, uma com oclusão de óculos e outra com oclusão de cachecol como forma de deixar as bases comparáveis em termos de oclusões, obtendo-se assim 30 imagens parcialmente ocluídas. Uma observação importante a respeito das máscaras de oclusões dessa base é que as mesmas foram obtidas por meio de recortes de imagens parcialmente ocluídas da base AR, conforme pode ser visto na Figura 42.

Figura 42 – Imagens da base de dados Yale e as respectivas máscaras de oclusão adicionadas

(a) e (d) imagens de oclusão presentes na base de dados Yale; (b) e (e) máscaras de oclusão; (c) e (f) imagens geradas utilizando as máscaras de oclusão.

Fonte: Jonas Mendonça Targino, 2019. As duas primeiras imagens foram obtidas da base Yale (GEORGIADES; BELHUMEUR; KRIEGMAN, 1997)

7.3 Divisões dos experimentos

Visando entender o comportamento das técnicas de reconstrução, foi necessário separar cada tipo de oclusão e outras variações (tais como iluminação) associadas à oclusão. Analisando as duas bases de dados, percebeu-se que a base de dados AR apresentava algumas variações de oclusões, a saber: (i) oclusões parciais de cachecol; (ii) de óculos; (iii) e de cachecol e óculos com variações de iluminação. Já base de dados Yale apresentava oclusões de cachecol e óculos, as quais foram inseridas de maneira artificial utilizando a máscara de oclusão da base AR. Com base nisto, foi possível dividir as bases de dados em 6 grupos, com siglas referentes a base e número do experimento. Essas siglas podem ser visualizadas a seguir:

1. **AR#1**: contém todas as imagens parcialmente ocluídas presentes na base de dados AR, totalizando 1200 imagens;
2. **AR#2**: contém as imagens sem iluminação presentes na base AR com oclusão de óculos de sol e cachecol, totalizando 400 imagens;

3. **AR#3**: contém as imagens apenas com oclusão de óculos de sol, totalizando 600 imagens;
4. **AR#4**: contém as imagens presentes na base AR que possuem oclusões parciais de cachecol, totalizando 600 imagens;
5. **Yale#1**: compreende 15 imagens da base Yale com oclusões de óculos;
6. **Yale#2**: compreende 15 imagens da base Yale com oclusões de cachecol.

Vale destacar que o conjunto de treinamento é composto por imagens sem oclusão, ou seja, é independente do grupo.

7.4 Escolha do detector de oclusão

Para se identificar qual dos três detectores de oclusão apresentou melhores resultados de segmentação de pixels ocluídos utilizou-se nove máscaras de oclusão que foram segmentadas manualmente em imagens da base AR. Logo após inseriu-se essas nove máscaras de oclusões em todas as imagens sem oclusão conjunto de treinamento (base sem oclusão), de modo a visualizar e mensurar qual dos três detectores apresentava melhor resultado de segmentação, visto que com a seleção manual de cada uma das oclusões seria possível analisar a acurácia de detecção dos pixels ocluídos.

Dessa maneira na Figura 43 é possível visualizar de OC1 a OC9 as 9 máscaras de oclusão segmentadas manualmente, na segunda linha da mesma figura são apresentados nove exemplos de sobreposições da máscara sobre a imagem sem oclusão. E nas três linhas em seguida são apresentados alguns exemplos de segmentação dos pixels ocluídos com *Skin Tone*, Limiarização (com limiar igual a 78) e BMA (de dimensão 2×2). Após rápida análise visual das segmentações é possível perceber melhores segmentações dos pixels ocluídos com as técnicas Limiarização e BMA.

Desse modo, não só a análise visual torna-se um fator primordial para afirmar qual detector apresentou melhores segmentações. Tomando por base essa justificativa, foram analisadas as acurácias de detecção dos pixels ocluídos, e após a visualização dos resultados conforme a Figura 45 é possível afirmar que a técnica BMA apresentou os melhores resultados de segmentação nos nove tipos de oclusão presentes na base de dados.

Figura 43 – Detecção dos pixels ocluídos com as técnicas de detecção da oclusão parcial

Fonte: Jonas Mendonça Targino, 2019

Figura 44 – Acurácia de detecção

Fonte: Jonas Mendonça Targino, 2019

Nos experimentos realizados utilizou-se o BMA de dimensão de modo a tentar intensificar as zonas de bordas das máscaras de oclusão. Em função dos resultados alcançados, o BMA foi definido como técnica para detecção da oclusão em todos os experimentos. A Figura 45 ilustra algumas máscaras de oclusão obtidas com BMA.

Após a detecção da oclusão foram aplicados alguns operadores morfológicos com a finalidade de melhorar a segmentação da máscara de oclusão, possibilitando que pixels possivelmente ruidosos influenciem no processo de reconstrução. Dentre os operadores morfológicos utilizados, os que produziram melhores resultados foram: erosão, dilatação, abertura e fechamento. A aplicação desses operadores em uma imagem de face pode ser visualizada na Figura 46. Nesta Figura pode-se perceber a variação da imagem

Figura 45 – Máscaras de oclusões obtidas em algumas imagens da base de dados *AR*

Fonte: Jonas Mendonça Targino, 2019

original antes e depois da aplicação dos operadores morfológicos. Dentre os operadores morfológicos, o que produziu melhores resultados foi o operador de erosão. Este realça mais detalhadamente a região ocluída na imagem da face. No entanto todos os outros três operadores também foram utilizados, com iniciativas de produzir melhorias nas áreas de detecção da parte ocluída.

Figura 46 – Máscara de oclusão após a aplicação dos filtros morfológicos

Fonte: Jonas Mendonça Targino, 2019

7.5 Parâmetros utilizados

Neste trabalho foram utilizados uma quantidade considerável de parâmetros para as técnicas aqui apresentadas. Dessa forma esta seção possui como objetivo apresentar tais parâmetros, assim como também esclarecer eventuais dúvidas que possam ser necessárias para a replicação das técnicas.

7.5.1 Parâmetros das técnicas de reconstrução baseadas em subespaço

Um parâmetro em comum para as todas as técnicas baseadas em subespaço foi o percentual de representatividade de 95% para todo o conjunto. Entretanto algumas técnicas apresentam algumas especificidades, as quais são descritas logo abaixo:

- *Gappy* PCA: Utilizando como critério de parada 5000 iterações ou até que a norma do gradiente fosse menor que $1e^{-2}$, e para avanço do gradiente foi utilizado o α igual a 0.1.
- *Fast Robust* PCA: Para cada imagem foram selecionadas 256 amostras de pixels, contendo em cada amostra uma quantidade P de pixels selecionados de maneira randômica na imagem, como também nas imagens do treinamento. Todas as imagens foram redimensionadas para a dimensão (64 x 64) e com isso variou-se o P igual a 256, 512, 1024 e 2048. De modo que essa técnica possui 4 iterações, ou seja, uma iteração para cada valor de P , dessa forma $T = 4$.
- *Fast Recursive* PCA: Nessa técnica utilizou-se o valor de α igual a 0.1. E como critério de parada também utilizou-se 5000 iterações ou até que a diferença entre os coeficientes de combinação linear fossem menor que $1e^{-2}$.
- *Recursive* PCA: Também utilizando a parametrização similar ao *Fast Recursive* PCA, essa técnica utilizou α igual a 0.1. E os critérios de parada do algoritmo foram 5000 iterações ou até que a diferença entre os coeficientes de combinação linear fossem menor que $1e^{-2}$.
- SRC com *Fast Rec* PCA: Utilizou todas as imagens do treinamento para aplicação da SRC, logo após o retorno da SRC foram utilizados as 20 imagens com maiores valores dos coeficientes de correlação retornados pela SRC. E com isso gerado o espaço de faces com três indivíduos, enquanto na técnica de reconstrução utilizou-se

valor de α igual a 0.1, e como critério de parada definiu-se 5000 iterações ou até que a diferença entre os coeficientes de combinação linear fossem menor que $1e^{-2}$.

7.5.2 Parâmetros das técnicas de reconstrução baseadas em modelo

- SRC GP: Foi utilizada todas as imagens do conjunto de treinamento e aplicada a representação esparsa na imagem de consulta de modo a utilizar as 20 imagens com maiores valores de α retornados pela SRC. Utilizando os 4 pixels vizinhos para geração do grafo de Poisson. E para reconstrução da imagem foi utilizado o limiar κ igual a 0.9, de modo que esse limiar significa o quão serão multiplicados os pixels obtidos com o sistema linear proveniente do sistema gerado pela equação da matriz Laplaciana.
- SRC GL: De modo similar ao SRC GP nessa técnica foi utilizada a mesma parametrização, diferenciando apenas no processo de geração do grafo, em que nessa técnica foi aplicada a topologia do grafo Laplaciano. Esse tipo de grafo utilizando os 10 nós vizinhos para geração do grafo. Também utilizando o limiar κ igual a 0,9.
- SSIMGL: Essa técnica inicialmente reduziu todas as imagens para a dimensão (32×32) de modo a reduzir o tempo computacional. Utilizando os 10 nós vizinhos para geração do grafo Laplaciano. Também utilizando o κ igual a 0,9 para reconstrução das imagens.

7.5.3 Configurações do extrator de características

Para a extração de características foi aplicada a Transformada Wavelet utilizando três níveis de decomposição. Foram utilizados apenas os coeficientes de aproximação (LL). As seguintes funções Wavelet foram utilizadas: Daubechies 2, Daubechies 4, Symlet 3, Symlet 4 e Symlet 5. Na Tabela 1 são apresentadas as funções Wavelets e suas respectivas quantidades de características (coeficientes de aproximação) extraídas por cada nível de decomposição.

Tabela 1 – Número de características extraídas com a transformada Wavelet de acordo com cada nível de decomposição

Função Wavelet	# características		
	LL1	LL2	LL3
Daubechies 2	4225	1156	324
Daubechies 4	4489	1369	484
Symlet 3	4356	1225	400
Symlet 4	4489	1369	484
Symlet 5	4624	1444	529

Fonte: Jonas Mendonça Targino, 2019

Após a extração dos coeficientes, estes foram normalizados utilizando média e desvio padrão conforme apresentado em (GALDI; NAPPI; DUGELAY, 2016). Desta forma, cada coluna apresenta média 0 e desvio padrão 1, utilizando a equação 76, em que x_j , $\bar{x}_j$ e σ_j significam respectivamente a j -ésima coluna da matriz de dados, sua média e seu desvio padrão.

$$f(x_j) = \frac{(x_j - \bar{x}_j)}{\sigma_j} \quad (76)$$

7.5.4 Parâmetros dos classificadores

Os classificadores discutidos neste trabalho foram implementados usando a linguagem de programação Matlab, com exceção do SVM. Neste caso, a biblioteca libsvm (CHANG; LIN, 2011) foi utilizada. Os parâmetros de cada técnica são descritos abaixo:

- KNN - Neste classificador utilizou-se distância Euclidiana e os seguintes valores de k : 1, 2, 4, 6, 8 e 10.
- ELM - Neste classificador foi utilizada a função de ativação sigmóide nos neurônios da camada intermediária. Utilizando os seguintes números de neurônios na camada escondida: 200, 500, 1000, 2000 e 4000. Tais parâmetros foram utilizados com base no trabalho de Finizola et al. (2018).
- SVM - Utilizou a função de *kernel* de base radial, o parâmetro C , que é responsável por controlar o limiar de maximização da margem e minimização do erro, foi fixado em 1000. E para os parâmetros γ que significam a variância, esses seguiram uma parametrização similar a utilizada no trabalho de Finizola et al. (2018), sendo a

parametrização: $2e^{-3}$, $2e^{-4}$, $2e^{-5}$, $2e^{-6}$, $2e^{-7}$, $2e^{-8}$ e $2e^{-9}$. Essa parametrização também foi utilizada de acordo com alguns experimentos em que verificou-se que esse intervalo possibilita menor taxa de erro do SVM. A Figura 47 ilustra o comportamento do SVM ao utilizar o γ entre $2e^{-1}$ e $2e^{-10}$, com o auxílio dessa Figura é possível perceber que os intervalos entre $2e^{-3}$ e $2e^{-9}$ possibilitam menores taxas de erro desse classificador.

Figura 47 – Comportamento do SVM ao se variar os valores de σ

Fonte: Jonas Mendonça Targino, 2019

7.6 Métricas para análise das técnicas

Para avaliar o comportamento das técnicas de reconstrução e mensurar qual técnica apresentou melhores resultados em termos de qualidade da imagem foram utilizadas técnicas de validação da imagem reconstruída como RMSE, SSIM e PSNR. Paralelamente para avaliar as técnicas em termos de performance foram utilizadas outras métricas como taxa de acurácia, matriz de confusão, F1-Score, curvas ROC e curvas de FAR e FRR.

8 Experimentos e análises de resultados

8.1 Resultados obtidos usando imagens com oclusão

Antes de apresentar a acurácia alcançada no reconhecimento ao utilizar técnicas de detecção e reconstrução de oclusão, é interessante saber a acurácia obtida usando imagens com oclusão sem nenhum processamento. Para a tarefa de classificação foram utilizados os seguintes classificadores: ELM, KNN e SVM.

Analisando os grupos gerados na seção anterior é interessante investigar a acurácia obtida individualmente por grupo usando imagens de faces parcialmente ocluídas. A Figura 48 apresenta a acurácia obtida para os seis grupos gerados usando as duas bases de dados e os classificadores KNN, ELM e SVM. Analisando Figura 48, pode-se perceber que nos quatro grupos gerados a partir da base AR há imagens com oclusão que dificultam o reconhecimento, implicando em baixas taxas de reconhecimento. Já os dois grupos gerados a partir da base Yale há imagens ocluídas sem variações de iluminação. Neste caso, foi possível obter uma acurácia de 100% nos grupos usando o classificador SVM. Com base nesta discussão, as técnicas de detecção e reconstrução serão aplicadas a todos os grupos, porém esse trabalho dará maior ênfase aos quatro grupos da base AR por apresentarem oclusões naturais.

Figura 48 – Acurácia obtida por grupo usando os coeficientes de aproximação do nível 3 de decomposição e os classificadores KNN, ELM e SVM

Fonte: Jonas Mendonça Targino, 2019

8.2 Resultados obtidos usando técnicas baseadas em subespaço

Nesta seção são apresentadas as imagens reconstruídas por cada técnica baseada em subespaço, análises das métricas de validação da imagem, acurácia de classificação, análise de erro por classe de cada técnica, assim como também suas respectivas curvas de FAR e FRR, todas essas métricas sendo avaliadas de acordo com cada grupo de oclusão.

De modo a identificar todas as técnicas baseadas em subespaço foram criadas algumas abreviações de modo a realizar o posicionamento de maneira satisfatória frente a leitura do texto. Essas abreviações estão dispostas no quadro 1.

Quadro 1 – Abreviações geradas para algumas técnicas baseadas em subespaço

Técnica	Abreviação
Base com oclusão	BO
Asymmetrical PCA	APCA
Fast Robust PCA	FRPCA
Recursive PCA	Rec PCA
Fast Recursive PCA	Fast Rec PCA
Gappy PCA	GPCA
SRC Fast Recursive PCA	SRC Fast Rec PCA

Fonte: Jonas Mendonça Targino, 2019

8.2.1 Resultados obtidos para os grupos da base AR

Inicialmente foram realizados alguns experimentos preliminares com um número limitado de imagens, os quais demonstraram que as técnicas SRC Fast Rec PCA, Rec PCA e Fast Rec PCA, perceptivelmente apresentaram melhores imagens reconstruídas quando comparadas as outras técnicas baseadas em subespaço, conforme ilustra a Figura 49, em que são apresentadas oito imagens reconstruídas de dois indivíduos. Essas técnicas apresentarem melhores resultados, visto que minimizam os coeficientes de combinação linear. Um grande diferencial das técnicas SRC Fast Rec PCA, Rec PCA e Fast Rec PCA é a substituição dos pixels não ocluídos pelos respectivos pixels da imagem original, de modo a evitar inserções de ruídos na imagem reconstruída.

Figura 49 – Exemplos de imagens reconstruídas de dois indivíduos de acordo com os grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Após a realização dos experimentos preliminares, as técnicas baseadas em subespaço foram aplicadas a base de dados AR e Yale. Em seguida foi realizada a análise da qualidade das imagens reconstruídas usando as métricas RMSE, SSIM e PSNR. Para o cálculo dessas métricas foi assumido que se conhece o indivíduo. Na Tabela 2 é possível visualizar os resultados em termos de RMSE das técnicas baseadas em subespaço. Nessa mesma tabela é possível perceber que a técnica SRC Fast Rec PCA apresentou melhores resultados de RMSE, seguida pela técnica GPCA, Fast Rec PCA e Rec PCA. Por último a técnica *Fast Robust PCA* foi a técnica que apresentou os piores resultados.

Tabela 2 – Avaliação das técnicas de reconstrução baseadas em subespaço aplicadas aos grupos da base de dados AR usando RMSE

Técnica	RMSE			
	AR#1	AR#2	AR#3	AR#4
	média $\pm$ desvio	média $\pm$ desvio	média $\pm$ desvio	média $\pm$ desvio
APCA	73.37 $\pm$ 11.09	66.43 $\pm$ 12.55	69.67 $\pm$ 10.02	77.07 $\pm$ 10.88
FRPCA	94.58 $\pm$ 13.48	82.37 $\pm$ 9.42	98.18 $\pm$ 12.34	90.99 $\pm$ 13.63
Fast Rec PCA	54.59 $\pm$ 13.86	38.08 $\pm$ 8.46	52.98 $\pm$ 14.48	56.20 $\pm$ 13.02
GPCA	53.09 $\pm$ 13.31	36.91 $\pm$ 7.14	52.07 $\pm$ 14.02	54.10 $\pm$ 12.50
PCA	72.92 $\pm$ 10.39	69.83 $\pm$ 12.47	70.07 $\pm$ 10.01	75.78 $\pm$ 9.97
Rec PCA	54.59 $\pm$ 13.86	38.07 $\pm$ 8.48	52.97 $\pm$ 14.49	56.20 $\pm$ 13.02
Fisherfaces	58.76 $\pm$ 7.61	53.53 $\pm$ 6.35	61.57 $\pm$ 6.80	55.95 $\pm$ 7.34
SRC Fast PCA	49.09$\pm$18.84	25.84 $\pm$ 9.98	50.42 $\pm$ 20.19	47.76$\pm$17.30

Fonte: Jonas Mendonça Targino, 2019

A Tabela 3 apresenta os valores obtidos usando SSIM para medir a qualidade das imagens reconstruídas pelas técnicas baseadas em subespaço. Analisando os resultados, pode-se concluir que as técnicas SRC Fast Rec PCA, GPCA, Rec PCA e Fast Rec PCA, nesta ordem, apresentam os melhores para a base de dados AR. Por outro lado, a técnica *Fast Robust PCA* apresentou os piores resultados.

Tabela 3 – Avaliação das técnicas de reconstrução baseadas em subespaço aplicadas aos grupos da base de dados AR usando SSIM

Técnica	SSIM			
	AR#1	AR#2	AR#3	AR#4
	média $\pm$ desvio	média $\pm$ desvio	média $\pm$ desvio	média $\pm$ desvio
APCA	0.42 $\pm$ 0.06	0.45 $\pm$ 0.06	0.45 $\pm$ 0.05	0.39 $\pm$ 0.05
FRPCA	0.46 $\pm$ 0.04	0.50 $\pm$ 0.04	0.48 $\pm$ 0.04	0.45 $\pm$ 0.05
Fast Rec PCA	0.52 $\pm$ 0.07	0.59 $\pm$ 0.06	0.54 $\pm$ 0.06	0.50 $\pm$ 0.08
GPCA	0.55 $\pm$ 0.07	0.61 $\pm$ 0.06	0.56 $\pm$ 0.06	0.53 $\pm$ 0.08
PCA	0.37 $\pm$ 0.05	0.39 $\pm$ 0.05	0.39 $\pm$ 0.05	0.36 $\pm$ 0.05
Rec PCA	0.52 $\pm$ 0.07	0.59 $\pm$ 0.06	0.54 $\pm$ 0.06	0.50 $\pm$ 0.08
Fisherfaces	0.36 $\pm$ 0.06	0.41 $\pm$ 0.04	0.34 $\pm$ 0.05	0.38 $\pm$ 0.05
SRC Fast PCA	0.63$\pm$0.10	0.71$\pm$0.09	0.65$\pm$0.08	0.60$\pm$0.11

Fonte: Jonas Mendonça Targino, 2019

Na Tabela 4 é apresentado os valores de PSNR usado medir a qualidade das imagens reconstruídas pelas técnicas baseadas em subespaço. Neste caso, foram obtidos resultados similares aos alcançados com RMSE e a SSIM. Novamente a técnica *Fast Robust PCA* apresentou os piores resultados.

Tabela 4 – Avaliação das técnicas de reconstrução baseadas em subespaço aplicadas aos grupos da base de dados AR usando PSNR

Técnica	PSNR			
	AR#1	AR#2	AR#3	AR#4
	média ± desvio	média ± desvio	média ± desvio	média ± desvio
APCA	10.56±1.42	11.47±1.60	11.00±1.46	10.12±1.23
FRPCA	8.34±1.61	9.51±1.42	8.00±1.48	8.69±1.67
Fast Rec PCA	13.35±2.62	16.35±1.96	13.67±2.84	13.04±2.34
GPCA	13.59±2.62	16.58±1.95	13.81±2.85	13.37±2.36
PCA	10.60±1.19	11.03±1.42	10.95±1.18	10.25±1.09
Rec PCA	13.35±2.62	16.36±1.96	13.67±2.84	13.04±2.34
Fisherfaces	12.46±1.46	13.25±1.38	12.03±1.33	12.88±1.47
SRC Fast PCA	14.83±4.31	20.09±3.05	14.70±4.57	14.96±4.03

Fonte: Jonas Mendonça Targino, 2019

Após a análise das métricas de qualidade da imagem, foi utilizada a taxa de acurácia de modo a complementar o estudo realizado. Neste caso, cada técnica de reconstrução é avaliada usando o resultado da tarefa de classificação. A Figura 50 ilustra o comportamento das técnicas baseadas em subespaço com classificador KNN utilizando os coeficientes de aproximação do nível 3 de decomposição da Transformada Wavelet. Analisando os resultados, pode-se observar que SRC Fast Rec PCA obteve os melhores resultados, isto é, obteve taxas de acerto igual a 84.58%, 92.50%, 93.83% e 75.33% para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Por outro lado, Fast Rec PCA, Rec PCA e GPCA apresentaram acurácias próximas a 80% apenas para o grupo AR#3. Para o grupo AR#4, com exceção da SRC Fast Rec PCA, todas as outras técnicas produziram acurácia menor que 28%.

Figura 50 – Acurácia obtida na base de dados AR usando classificador KNN e coeficientes de aproximação do nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

A Figura 51 apresenta o comportamento das técnicas baseadas em subespaço com classificador KNN utilizando os coeficientes de aproximação do nível 2 de decomposição da Transformada Wavelet. Analisando os resultados, similar ao comportamento observado para os coeficientes de aproximação do nível 3 de decomposição, o SRC Fast Rec PCA apresentou os melhores resultados, isto é, alcançou a acurácia igual a 86%, 93%, 94.83% e 77.33% para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Para o grupo AR#3, as Fast Rec PCA, Rec PCA e GPCA apresentaram acurácia próximas a alcançada pela SRC Fast Rec PCA.

Figura 51 – Acurácia obtida na base de dados AR usando classificador KNN e coeficientes de aproximação do nível 2 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

A Figura 52 apresenta os resultados para o classificador KNN usando os coeficientes de aproximação do nível 1 de decomposição da Transformada Wavelet. Novamente o melhor resultado foi alcançado usando a técnica SRC Fast Rec PCA. Neste caso, foi obtida a acurácia de 86.75%, 93%, 95.16%, 78.33 % para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente.

Figura 52 – Acurácia obtida na base de dados AR usando classificador KNN e coeficientes de aproximação do nível 1 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Na Figura 53 é apresentado o desempenho de cada técnica baseada em subespaço aplicada na tarefa de reconstrução. Neste caso, foi utilizado classificador ELM e os coeficientes de aproximação do nível 3 de decomposição da TW. Analisando os resultados, que os melhores resultados, em termos de acurácia, foram alcançados pelas técnica SRC Fast Rec PCA, Rec PCA, Fast Rec PCA e GPCA. A técnica SRC Fast Rec PCA alcançou percentuais de taxa de reconhecimento iguais a 89.33%, 94.75%, 96.33% e 83% nos grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Obtendo ganhos de reconstrução iguais a 42.48%, 39.55%, 44.82% e 38.79%, nos grupos AR#1, AR#2, AR#3 e AR#4 respectivamente.

Figura 53 – Acurácia obtida na base de dados AR usando classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

A Figura 54 ilustra os resultados obtidos usando ELM e coeficientes de aproximação do nível 2 de decomposição. A técnica SRC Fast Rec PCA apresentou os melhores resultados em todos os quatro grupos da base AR. Neste caso, foi alcançado acurácia iguais a 90.17%, 95.50%, 96.17% e 84.67% para os grupos AR#1, AR#2, AR#3 e AR#4. As técnicas Rec PCA e Fast Rec PCA apresentaram resultados similares a SRC Fast Rec PCA para os grupos AR#2 e AR#3.

Figura 54 – Acurácia obtida na base de dados AR usando classificador ELM e coeficientes de aproximação do nível 2 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Na Figura 55 é apresentado os resultados obtidos usando classificador ELM e coeficientes de aproximação do nível 1 de decomposição. Novamente, técnica SRC Fast Rec PCA apresentou os melhores resultados em termos de acurácia, seguida pela técnica Rec PCA, Fast Rec PCA e GPCA. A técnica SRC Fast Rec PCA obteve acurácias iguais a 90.25%, 94.50%, 95.16% e 84.50%, e ganhos de reconstrução de 30%, 30%, 33.16% e 24.84% para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente.

Figura 55 – Acurácia obtida na base de dados AR usando classificador ELM e coeficientes de aproximação do nível 1 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Na Figura 56 é apresentado os resultados obtidos usando SVM e coeficientes de aproximação do nível 3 de decomposição. O melhor resultado foi obtido com a técnica SRC Fast Rec PCA. Neste caso, foram obtidos acurácias iguais a 89.25%, 94.25%, 95.83% e 84.00% nos grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Por outro lado, as técnicas Rec PCA, Fast Rec PCA e GPCA apresentaram taxas de reconhecimento menores que a apresentada pela técnica SRC Fast Rec PCA.

Figura 56 – Acurácia obtida na base de dados AR usando classificador SVM e coeficientes de aproximação do nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

A Figura 57 apresenta os resultados obtidos usando o classificador SVM e os coeficientes de aproximação do nível 2 de decomposição. Novamente o melhor resultado foi obtido usando a técnica SRC Fast Rec PCA. Foram obtidas acurácias iguais a 90.08%, 95.00%, 96.33% e 85.16% para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Vale a pena mencionar que o classificador SVM ao lidar com pequenas oclusões parciais como oclusão de óculos, produz melhores resultados quando comparado aos classificadores KNN e ELM.

Figura 57 – Acurácia obtida na base de dados AR usando classificador SVM e coeficientes de aproximação do nível 2 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Ao utilizar os coeficientes de aproximação do nível 1 de decomposição da TW e classificador SVM foi possível perceber ganhos, em termos de acurácia, para os coeficientes do nível 2 de aproximação da TW. Neste caso a técnica SRC Fast Rec PCA apresentou ganhos de 0.42% e 0.67 respectivamente nos grupos AR#1 e AR#4, conforme ilustra a Figura 58. Já as técnicas Rec PCA, Fast Rec PCA e GPCA apresentaram ganhos para todos os grupos.

Figura 58 – Acurácia obtida na base de dados AR usando classificador SVM e coeficientes de aproximação do nível 1 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Com base nos resultados apresentados acima, é necessário analisar o ganho obtido ao variar o nível de decomposição da TW. Assim será possível verificar investigar a influência de cada nível para o reconhecimento da técnica. Vale a pena ressaltar que a quantidade de coeficientes de aproximação reduz quando aumenta-se o nível de decomposição. Logo, quanto maior o nível de decomposição menor será o vetor de características utilizado como entrada para o classificador. Na tentativa de facilitar o entendimento dos resultados foram criadas algumas siglas para diferenciá-las das demais. A sigla BO representa a base ocluída, e as siglas T1 a T8 representam respectivamente as técnicas APCA, FRPCA, Fast Rec PCA, Rec PCA, GPCA, PCA, Fisherfaces e SRC Fast Rec PCA.

A Figura 59 apresenta os ganhos alcançados pelo classificador KNN. Analisando os resultados, pode-se perceber ganhos próximos entre os coeficientes dos níveis de decomposição 1 e 2. Na mesma Figura 59 é possível visualizar maiores ganhos ao se utilizar o nível 2 de decomposição da TW.

Figura 59 – Ganhos obtidos pelas técnicas baseadas em subespaço e classificador KNN ao variar os níveis de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Analizando a Figura 60, que apresenta os ganhos alcançados pelo classificador ELM, é possível perceber melhorias na acurácia. Por outro lado, as técnicas GPCA, Fast Rec PCA e Rec PCA apresentaram comportamentos similares. Além disso, pode-se notar que a técnica SRC Fast Rec PCA apresentou resultados próximos, em termos de acurácia, ao utilizar os níveis de decomposição 1, 2 e 3.

Figura 60 – Ganhos obtidos pelas técnicas baseadas em subespaço e classificador ELM ao variar os níveis de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

A Figura 61 apresenta os ganhos produzidos pelo classificador SVM ao variar os níveis de decomposição da TW. Neste caso, pode-se perceber que os melhores resultados foram obtidos usando os coeficientes de aproximação do nível 2 de decomposição.

Figura 61 – Ganhos obtidos pelas técnicas baseadas em subespaço e classificador SVM ao variar os níveis de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Ao demonstrar os resultados das técnicas em termos de acurácia e métricas de qualidade da imagem torna-se interessante também analisar o comportamento das técnicas em termos estatísticos. Dessa forma foi aplicado o teste estatístico de Wilcoxon (LITCHFIELD; WILCOXON, 1949) sobre as acurácias alcançadas. Esse é um método não paramétrico para análise de resultados de duas amostras pareadas, de forma que são calculados os valores numéricos da diferença entre cada par. Dessa forma, a amostra da melhor técnica baseada em subespaço foi comparada com as demais. Essas amostras foram obtidas por meio das 10 execuções da ELM para cada técnica.

A hipótese nula diz que as amostras de cada técnica são oriundas da mesma distribuição com nível significância (α) igual a 0.05. Um valor p maior que α significa que não podemos rejeitar a hipótese nula. Enquanto um valor p menor que α significa que a hipótese nula foi rejeitada. Logo as duas técnicas possuem distribuições significativamente diferentes e pode-se afirmar que a técnica que apresentou maior acurácia média é a melhor.

Dessa forma o teste de Wilcoxon foi utilizado neste trabalho para validar se a técnica SRC com Fast Recursive PCA apresentou os melhores resultados, dessa forma

o teste a utilizou como base e comparou com as demais técnicas para os quatro grupos da base AR. Em que foi possível verificar rejeição da hipótese nula para todos os grupos e todas as técnicas. Dessa forma podendo afirmar que dentre as técnicas baseadas em subespaço a técnica SRC com Fast Recursive PCA realmente apresentou os melhores resultados.

Mediante análise das técnicas apresentadas acima pode-se perceber que os resultados alcançados, em termos de acurácia pelas técnicas *Recursive PCA* e *Fast Recursive PCA* ficaram muito próximos. Logo, é necessário analisar o erro por classe para cada técnica. A Figura 62 é apresentado o erro por classe da técnica *Recursive PCA*. Neste caso, a maior incidência de erro por classe dessa técnica acontece nos grupos AR#1 e AR#4, os quais apresentam respectivamente imagens ocluídas com variações de iluminação e imagens com oclusão parcial de cachecol.

Os erros alcançados pela técnica *Recursive PCA* são justificados devido as imagens ocluídas possuírem poucos pixels não ocluídos. Além disso, as variações de iluminações possibilitam maior distanciamento do espaço de faces, possibilitando que a combinação linear dos *eigenfaces* produza uma imagem com maiores ruídos. Portanto, os grupos que apresentaram menor taxa de erro foram os grupos AR#2 e AR#3. Neste caso, as oclusões de óculos são um pouco menores que oclusões de cachecol, e a ausência de variação de iluminação na imagem favorece a reconstrução da imagem.

Figura 62 – Distribuição das taxas de erro geradas pela técnica *Recursive PCA* usando o classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

A distribuição das taxas de erro para a técnica *Gappy* PCA é apresentada na Figura 63. Analisando os resultados, pode-se perceber que as maiores taxas de erros foram alcançadas para os grupos AR#1 e AR#4. Para o grupo AR#2, como este apresenta oclusões sem variações de iluminação, a técnica *Gappy* PCA apresentou menor taxa de erros por classe quando comparado com os outros grupos.

Figura 63 – Distribuição das taxas de erro geradas pela técnica *Gappy* PCA usando o classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Conforme mencionado anteriormente, a técnica SRC com Fast Rec PCA apresentou os melhores resultados quando comparada com as outras técnicas baseadas em subespaço. A Figura 64 apresenta a distribuição dos erros produzidos pela técnica SRC com Fast Rec PCA. Analisando os resultados, pode-se notar que os menores erros foram alcançados para os grupos grupos AR#2 e AR#3 e os maiores erros para o grupo AR#4.

Figura 64 – Distribuição das taxas de erro geradas pela técnica SRC com *Fast Recursive PCA* usando o classificador ELM e coeficientes de aproximação do nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Uma alternativa interessante ao analisar cada técnica é verificar quais indivíduos apresentaram maiores taxas de erros e com quais outros indivíduos (classe) foram confundidos. Dessa forma foram analisados os erros por classe das técnicas *Recursive PCA*, *Gappy PCA* e *SRC Fast Rec PCA*. Mediante tal propósito a Figura 65 ilustra em cada grupo da base AR quais classes obtiveram maior taxa de erro e ao lado a classe com a qual foi confundida. Por exemplo, na Figura 65 para o grupo AR#1, a classe 82 apresentou o maior erro de reconhecimento, e na maioria desses erros a mesma foi confundida com a classe 72, levando em conta a técnica *Recursive PCA*. Logo, pode-se observar que as classes 82, 57, 82 e 26 apresentaram maiores erros para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Tais classes foram confundidas com as classes 72, 48, 17 e 23 respectivamente.

Figura 65 – Distribuição dos erros por Classes para cada grupo da base AR usando classificador ELM e a técnica Recursive PCA

Fonte: Jonas Mendonça Targino, 2019

Ao analisar os erros por classe da técnica *Fast Recursive PCA*, observou-se um comportamento similar ao *Recursive PCA*. Com base nisso, aqui são apresentados os erros por classe apenas da técnica *Recursive PCA*.

Na Figura 66 são apresentadas as classes que apresentaram maiores taxas de erro e a classe atribuída erroneamente pelo classificador para a técnica *Gappy PCA*. Analisando os resultados, pode-se perceber que as classes 57, 95, 82 e 26 apresentaram maiores erros para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente, as quais foram confundidas com as classes 5, 29, 19 e 42 nesta ordem.

Figura 66 – Distribuição dos erros por Classes para cada grupo da base AR usando classificador ELM e a técnica técnica Gappy PCA

Fonte: Jonas Mendonça Targino, 2019

Enquanto a técnica SRC Fast Rec PCA apresentou maiores erros por classe para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente, neste caso, as classes 77, 26, 39 e 77 foram confundidas com as classes 94, 74, 3 e 94 respectivamente. Na Figura 67 são apresentadas as classes com maiores erros por grupo e as classes com as quais foram confundidas.

Figura 67 – Distribuição dos erros por Classes para cada grupo da base AR usando classificador ELM e a técnica técnica SRC Fast Rec PCA

Fonte: Jonas Mendonça Targino, 2019

Dado a distribuição dos erros, é interessante investigar outras métricas de desempenho, tais como precisão, F1-Score e MCC. Na Tabela 5 são apresentadas essas métricas para cada grupo da base AR usando classificador ELM e a técnica *Fast Recursive PCA*.

Tabela 5 – Resultados das métricas usadas para avaliar o desempenho da *Fast Recursive PCA* ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-Score	MCC
AR#1	0.7408	0.8113	0.7517	0.9236
AR#2	0.8925	0.9280	0.8926	0.9003
AR#3	0.8567	0.8927	0.8569	0.8642
AR#4	0.6500	0.8483	0.6702	0.7126

Fonte: Jonas Mendonça Targino, 2019

De forma paralela, na Tabela 6 são apresentados os valores das métricas a partir da técnica de reconstrução *Gappy PCA*. Pode-se perceber uma queda de performance para todas as métricas quando comparada com a técnica *Fast Recursive PCA*.

Apresentando resultados muito próximos a técnica *Fast Recursive PCA*, a técnica *Recursive PCA* também demonstrou proximidades nas métricas de desempenho, apre-

Tabela 6 – Resultados das métricas usadas para avaliar o desempenho da *Gappy* PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-Score	MCC
AR#1	0.6425	0.8170	0.6707	0.6947
AR#2	0.8150	0.8939	0.8217	0.8334
AR#3	0.7450	0.8490	0.7514	0.7703
AR#4	0.5983	0.8356	0.6502	0.6733

Fonte: Jonas Mendonça Targino, 2019

sentando valores das métricas bem próximos. Tais resultados estão dispostos na Tabela 7.

Tabela 7 – Resultados das métricas usadas para avaliar o desempenho da *Recursive* PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-Score	MCC
AR#1	0.7425	0.8183	0.7537	0.7631
AR#2	0.8925	0.9285	0.8926	0.9004
AR#3	0.8583	0.8977	0.8599	0.8662
AR#4	0.6533	0.8475	0.6971	0.7153

Fonte: Jonas Mendonça Targino, 2019

Enquanto ao verificar as métricas de desempenho com a técnica SRC Fast Rec PCA foi possível perceber os melhores resultados dentre todas as outras técnicas baseadas em subespaço. Apresentando percentuais superiores de todas as métricas quando comparada as outras técnicas baseadas em subespaço. Sobressaindo-se com consideráveis percentuais perante os quatro grupos da base AR, de modo especial com melhores resultados nos grupos AR#3, AR#2 e AR#1. Atuando como uma boa técnica que pode ser associada aos mais variados tipos de ambiente.

Tabela 8 – Resultados das métricas usadas para avaliar o desempenho da *Recursive* PCA ao utilizar classificador ELM e coeficientes Wavelet do nível 3 de decomposição para os quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-score	MCC
AR#1	0.8983	0.9132	0.8948	0.8980
AR#2	0.9475	0.9578	0.9458	0.9487
AR#3	0.9633	0.9695	0.9623	0.9640
AR#4	0.8300	0.8816	0.8286	0.8400

Fonte: Jonas Mendonça Targino, 2019

Tomando por base os resultados em termos de acurácia das técnicas baseadas em subespaço aplicadas no contexto biométrico, percebeu-se a viabilidade de analisar as taxas de FAR e FRR. Na Figura 68 são apresentadas as taxas de FAR e FRR da técnica *Asymmetrical* PCA para os quatros grupos da base AR. Para os limiares de semelhança iguais a 0.42, 0.54, 0.38 e 0.45 nos grupos AR#1, AR#2, AR#3 e AR#4 respectivamente as taxas de FAR e FRR apresentam valores iguais. De modo que, ambas as taxas apresentam valores próximos de 0.40, 0.33, 0.41 e 0.42. Logo, para cada grupo ao utilizar um limiar de semelhança menor que os valores de intersecção das respectivas curvas de FAR e FRR (no caso 0.42, 0.54, 0.38 e 0.45) tem-se a taxa de falsa aceitação maior, e isso implica em aceitar uma maior quantidade de pessoas que não estão cadastradas no sistema, as quais o sistema deveria rejeitar. Por outro lado, ao utilizar limiares de semelhança maiores de que o ponto de intersecção (EER), estará rejeitando-se uma maior quantidade de indivíduos que deveriam ser aceitos pelo sistema.

Figura 68 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica *Asymmetrical* PCA

Fonte: Jonas Mendonça Targino, 2019

Enquanto na Figura 69 são apresentadas as taxas de FAR e FRR da técnica Fisherfaces nos quatros grupos da base AR. De modo que nos grupos AR#1, AR#2, AR#3 e AR#4 nos limiares de semelhança iguais a 0.33, 0.36, 0.31 e 0.35 respectivamente as taxas de FAR e FRR se cruzaram, nestes pontos apresentando valores iguais. Portanto, esses limiares de semelhança são os pontos ótimos de aceitação ou rejeição do sistema.

Figura 69 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Fisherfaces

Fonte: Jonas Mendonça Targino, 2019

Uma análise similar de FAR e FRR também foi realizada com a técnica *Fast Robust* PCA. Sendo possível extrair os limiares de semelhança entre a FAR e FRR, sendo eles 0.52, 0.49, 0.58 e 0.49 respectivamente para os grupos AR#1, AR#2, AR#3 e AR#4. Também é possível perceber o quão alto foi o valor da taxa de FAR e FRR chegando a valores próximos de 0.5 (0.39, 0.42, 0.46 e 0.51) para quase todos os grupos, definindo-se como não sendo uma boa técnica em termos de reconhecimento. Pois quanto menor o valor da taxa, melhor é a técnica.

Figura 70 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Fast Robust PCA

Fonte: Jonas Mendonça Targino, 2019

Enquanto a técnica PCA apresentou taxa de semelhança de FAR e FRR nos pontos 0.45, 0.55, 0.43 e 0.47 para os grupos AR#1, AR#2, AR#3 e AR#4. Paralelamente apresentando valores de FAR e FRR nos pontos de cruzamento (0.41, 0.44, 0.48 e 0.40) próximos a 0.5. Sendo 0.5 um valor consideravelmente alto, de modo que é desejável que quanto menor o valor da taxa de FAR e FRR melhor a técnica para o sistema de reconhecimento. As curvas de FAR e FRR, assim como também os pontos de intersecção EER podem ser visualizados com o auxílio da Figura 71.

Figura 71 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica PCA

Fonte: Jonas Mendonça Targino, 2019

Na análise da técnica *Gappy* PCA verificou-se os pontos de interseção das curvas de FAR e FRR de 0.5, 0.64, 0.56 e 0.44, de modo que nesses pontos a taxa de semelhança são iguais, conforme ilustra a Figura 72. Conforme a Figura é possível notar considerável nível de contribuição dessa técnica perante a tarefa de reconstrução.

Figura 72 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Gappy PCA

Fonte: Jonas Mendonça Targino, 2019

Já nas curvas de FAR e FRR da técnica *Recursive PCA* os pontos 0.48, 0.64, 0.51 e 0.43 dos grupos AR#1, AR#2, AR#3 e AR#4 respectivamente são os pontos EER, ou seja, são os pontos em que as duas curvas possuem valores iguais, tais resultados estão dispostos na Figura 73. Esses sendo os limiares ótimos do algoritmo de acordo com cada grupo. Um fato interessante dessa técnica é que ela foi uma das técnicas baseadas em subespaço que conseguiu os menores valores de taxa de FAR e FRR no ponto de intersecção entre as duas curvas. Desta forma confirmando uma técnica com considerável resultado perante as demais técnicas baseadas em subespaço. Sendo os valores das taxas 0.27, 0.27, 0.22 e 0.29 referentes aos grupos AR#1, AR#2, AR#3 e AR#4 respectivamente.

Figura 73 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica *Recursive PCA*

Fonte: Jonas Mendonça Targino, 2019

Uma outra técnica baseada em subespaço que apresenta-se promissora é a técnica *Fast Recursive PCA*, a qual é uma derivação do *Recursive PCA*, diferenciando-se apenas em sua velocidade de convergência. Ao ser analisada as curvas de FAR e FRR coincidiram com as taxas de FAR e FRR da técnica *Recursive PCA*. Com isso, demonstrando considerável nível de contribuição dessa técnica quando comparada a outras técnicas baseadas em subespaço com mais baixas performances. Tais resultados podem ser visualizados com o auxílio da Figura 74. Essa técnica como também o *Recursive PCA* atingiram consideráveis performances em todos os quatro grupos, destacando-se um pouco mais nos grupos AR#2 e AR#3.

Figura 74 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica Fast Recursive PCA

Fonte: Jonas Mendonça Targino, 2019

Das técnicas baseadas em subespaço a técnica que apresentou menores pontos de EER foi a técnica desenvolvida nesse trabalho, também intitulada SRC com *Fast Recursive PCA*. Como pode-se ver seus pontos de interseção das duas curvas aconteceu com valores de taxa 0.22, 0.19, 0.18 e 0.28 para os grupos AR#1, AR#2, AR#3 e AR#4. Tais curvas podem ser visualizadas com o auxílio da Figura 75. A partir da análise da Figura é possível perceber bons comportamentos da técnica nos grupos AR#2 e AR#3.

Figura 75 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SRC com *Fast Recursive PCA*

Fonte: Jonas Mendonça Targino, 2019

Deste modo, é possível concluir que das técnicas baseadas em subespaço a técnica SRC Fast Rec PCA foi a técnica que apresentou melhores curvas de FAR e FRR.

Dado que ao analisar as curvas de FAR e FRR, e os pontos EER para cada grupo sobre as técnicas de subespaço apresentadas. Dessa forma vale analisar o comportamento da performance da técnica após aplicação do limiar EER nos respectivos grupos. Com isso foram analisados os comportamentos das quatro melhores técnicas baseadas em subespaço, os quais estão dispostos na Tabela 9, sendo possível perceber que em alguns casos houve uma redução da acurácia após aplicação do limiar.

Tabela 9 – Análise da técnica após aplicação do limiar EER com classificador ELM

Grupo	Fast Rec PCA		Gappy PCA		Recursive PCA		SRC Fast PCA	
	Acurácia	EER	Acurácia	EER	Acurácia	EER	Acurácia	EER
AR#1	74.08%	74.08%	64.25%	64.16%	74.25%	74.25%	89.33%	89.33%
AR#2	89.25%	89.25%	81.75%	81.75%	89.25%	89.25%	94.75%	94.75%
AR#3	85.83%	85.83%	74.33%	73.66%	85.83%	85.83%	96.33%	96.33%
AR#4	65.16%	64.83%	60.00%	59.83%	65.33%	64.66%	83.00%	83.00%

8.2.2 Resultados das técnicas baseadas em subespaço nos grupos da base Yale

Ao utilizar as técnicas baseadas em subespaço nos dois grupos da base Yale foram vistos resultados similares de reconstrução aos apresentados nos quatro grupos da base AR.

Tais resultados de reconstrução são apresentados na Figura 76. Nesta Figura é possível perceber que as técnicas que apresentaram melhores imagens reconstruídas em nível de percepção visual foram as técnicas SRC Fast Rec PCA, Rec PCA, Fast Rec PCA e GPCA.

Figura 76 – Imagens reconstruídas com as técnicas baseadas em subespaço nos grupos da base Yale

Fonte: Jonas Mendonça Targino, 2019

Paralelamente também foram analisadas algumas métricas de validação das imagens reconstruídas. Sendo utilizadas as métricas RMSE, PSNR e SSIM. Na Tabela 10 são apresentados os valores de RMSE de cada técnica por grupo. Nessa tabela é possível perceber que o melhor resultado de RMSE para os dois grupos foram obtidos com a técnica SRC Fast Rec PCA. De todas as técnicas a técnica PCA foi a técnica que apresentou maiores valores de RMSE.

Tabela 10 – Resultados de RMSE das técnicas baseadas em subespaço nos grupos da base Yale

Técnica	RMSE	
	Yale#1	Yale#2
	média $\pm$ desvio	média $\pm$ desvio
APCA	58.65 $\pm$ 9.85	78.79 $\pm$ 11.82
FRPCA	61.80 $\pm$ 15.19	59.12 $\pm$ 14.54
Fast Rec PCA	53.01 $\pm$ 10.70	58.90 $\pm$ 9.85
Fisherfaces	71.29 $\pm$ 12.63	80.53 $\pm$ 9.54
GPCA	52.26 $\pm$ 10.52	54.61 $\pm$ 9.81
PCA	75.81 $\pm$ 17.59	92.79 $\pm$ 17.89
Recursive PCA	53.19 $\pm$ 10.55	54.84 $\pm$ 10.03
SRC Fast Rec PCA	51.08$\pm$12.73	52.28$\pm$11.26

Fonte: Jonas Mendonça Targino, 2019

Resultados similares nesses dois grupos também foram obtidos com a métrica PSNR, em que a técnica SRC Fast Rec PCA novamente apresentou os melhores resultados. Tais observações podem ser visualizadas com o auxílio da Tabela 11.

Tabela 11 – Resultados de PSNR das técnicas baseadas em subespaço nos grupos da base Yale

Técnica	PSNR	
	Yale#1	Yale#2
	média $\pm$ desvio	média $\pm$ desvio
APCA	12.87 $\pm$ 1.44	10.28 $\pm$ 1.28
FRPCA	12.56 $\pm$ 2.20	12.93 $\pm$ 2.11
Fast Rec PCA	13.81 $\pm$ 1.80	12.83 $\pm$ 1.40
Fisherfaces	11.19 $\pm$ 1.51	10.06 $\pm$ 1.02
GPCA	13.93 $\pm$ 1.81	13.52 $\pm$ 1.65
PCA	10.72 $\pm$ 1.81	8.93 $\pm$ 1.70
Recursive PCA	13.78 $\pm$ 1.79	13.49 $\pm$ 1.68
SRC Fast Rec PCA	14.23$\pm$2.29	13.94$\pm$1.81

Fonte: Jonas Mendonça Targino, 2019

Ao analisar a métrica SSIM nos dois grupos da base Yale, é possível perceber os melhores resultados com a técnica SRC Fast Rec PCA, seguidamente das técnicas GPCA, Rec PCA e Fast Rec PCA, conforme demonstrado na Tabela 12

Tabela 12 – Resultados de SSIM das técnicas baseadas em subespaço nos grupos da base Yale

Técnica	SSIM	
	Yale#1	Yale#2
	média $\pm$ desvio	média $\pm$ desvio
APCA	0.40 $\pm$ 0.04	0.34 $\pm$ 0.04
FRPCA	0.49 $\pm$ 0.05	0.49 $\pm$ 0.06
Fast Rec PCA	0.48 $\pm$ 0.04	0.41 $\pm$ 0.05
Fisherfaces	0.23 $\pm$ 0.05	0.18 $\pm$ 0.03
GPCA	0.50 $\pm$ 0.04	0.46 $\pm$ 0.05
PCA	0.29 $\pm$ 0.04	0.24 $\pm$ 0.04
Recursive PCA	0.48 $\pm$ 0.04	0.44 $\pm$ 0.05
SRC Fast Rec PCA	0.51 $\pm$ 0.07	0.48 $\pm$ 0.06

Fonte: Jonas Mendonça Targino, 2019

Ao analisar a acurácia das técnicas baseadas em subespaço nos dois grupos de oclusões da base Yale, verificou-se maiores dificuldades de reconhecimento no grupo Yale#2, visto que as técnicas SRC Fast Rec PCA, Rec PCA, Fast Rec PCA e GPCA apresentaram os melhores resultados de reconhecimento no grupo Yale#2 da base Yale. Enquanto a base ocluída conseguiu 100% de acurácia no grupo Yale#1, este grupo sendo definido como um grupo de oclusões que não implicam diretamente na taxa de reconhecimento. Considerando-se como um grupo que não necessita do processo de reconstrução. Tais resultados podem ser visualizados com o auxílio da Figura 77.

Figura 77 – Acurácia com KNN com nível 3 de decomposição da TW nos dois grupos da base Yale

Fonte: Jonas Mendonça Targino, 2019

Da mesma forma ao se analisar as técnicas com classificador ELM é possível perceber que as técnicas baseadas em subespaço Fast Rec PCA, Rec PCA e GPCA apresentaram 100% de reconhecimento para os dois grupos da base Yale. Justificando-se como ótimas técnicas quando apresentadas a bases de dados com baixo número de indivíduos. A Figura

78 ilustra o comportamento das técnicas baseadas em subespaço ao serem apresentadas com os dois grupos da base Yale.

Figura 78 – Acurácia com ELM com nível 3 de decomposição da TW nos dois grupos da base Yale

Fonte: Jonas Mendonça Targino, 2019

Enquanto ao avaliar-se os mesmos grupos com SVM conseguiu-se 100% de taxa de reconhecimento em quase todas as técnicas exceto com SRC Fast Rec PCA, Fisherfaces e PCA os quais apresentaram resultados inferiores de acurácia. Como ilustrado na Figura 79.

Figura 79 – Acurácia com SVM com nível 3 de decomposição da TW nos dois grupos da base Yale

Fonte: Jonas Mendonça Targino, 2019

Dado que a maioria das técnicas baseadas em subespaço apresentaram bons resultados na base Yale, aqui são apresentados apenas os resultados do terceiro nível de decomposição da TW.

8.3 Resultados das técnicas baseadas em modelo

De modo a identificar todas as técnicas baseadas em modelo foram criadas algumas abreviações para as técnicas de modo a realizar o posicionamento de maneira satisfatória frente a leitura do texto. Essas abreviações estão dispostos no quadro 2.

Quadro 2 – Abreviações geradas para as três técnicas baseadas em modelo

Técnica	Abreviação
SRC GP	SRC com grafo de Poisson
SRC GL	SRC com grafo Laplaciano
SSIMGL	Similaridade Estrutural com grafo Laplaciano

Fonte: Jonas Mendonça Targino, 2019

Após a reconstrução das imagens dos seis grupos nas duas bases de dados com as técnicas baseadas em modelo chegou-se aos resultados de reconstrução que serão apresentados logo abaixo.

8.3.1 Resultados nos quatro grupos da base AR

Na Figura 80 são apresentadas oito imagens reconstruídas de dois indivíduos sobre os quatro grupos da base AR com as três técnicas baseadas em modelo, com a ajuda da Figura é possível perceber imagens reconstruídas com poucos ruídos, implicando-se em boas técnicas de reconstrução.

Figura 80 – Exemplos de imagens de dois indivíduos reconstruídas com as técnicas baseadas em modelo

Fonte: Jonas Mendonça Targino, 2019

Ao analisarmos as métricas de qualidade das imagens reconstruídas pode-se perceber que a técnica SSIMGL foi a técnica que apresentou menores médias de erro (RMSE) para os quatro grupos presentes na base AR, conforme apresentado na Tabela 13. É possível perceber com o auxílio dessa tabela que a segunda melhor técnica baseada em modelo foi a técnica SRC GL.

Tabela 13 – Resultados de RMSE das técnicas baseadas em modelo

Técnica	RMSE			
	AR#1	AR#2	AR#3	AR#4
	média ± desvio	média ± desvio	média ± desvio	média ± desvio
SRC GP	51.21±18.45	29.61±12.28	51.58±19.74	50.84±17.07
SRC GL	51.17±18.47	29.59±12.56	51.42±19.81	50.91±17.04
SSIMGL	49.53±17.65	28.64±11.40	50.96±19.33	48.09±15.68

Fonte: Jonas Mendonça Targino, 2019

Resultados similares foram obtidos ao avaliar-se a métrica PSNR, de modo que a técnica SSIMGL apresentou os maiores valores de PSNR para os quatro grupos. Vindo a alcançar uma média de 19.33 para o grupo AR#2, conforme a Tabela 14.

Tabela 14 – Resultados de PSNR das técnicas baseadas em modelo

Técnica	PSNR			
	AR#1	AR#2	AR#3	AR#4
	média ± desvio	média ± desvio	média ± desvio	média ± desvio
SRC GP	14.38±4.18	19.12±3.72	14.43±4.46	14.34±3.88
SRC GL	14.40±4.21	19.16±3.79	14.48±4.52	14.32±3.88
SSIMGL	14.64±4.05	19.33±3.47	14.51±4.35	14.78±3.74

Fonte: Jonas Mendonça Targino, 2019

Ao analisar-se a métrica SSIM é possível perceber que novamente a métrica SSIMGL apresentou melhores resultados, conforme visualizado na Tabela 15. Chegando a obter 0.74 de SSIM no grupo AR#2.

Tabela 15 – Resultados de SSIM das técnicas baseadas em modelo

Técnica	SSIM			
	AR#1	AR#2	AR#3	AR#4
	média ± desvio	média ± desvio	média ± desvio	média ± desvio
SRC GP	0.62±0.11	0.71±0.11	0.65±0.10	0.59±0.11
SRC GL	0.62±0.11	0.72±0.11	0.65±0.10	0.59±0.11
SSIMGL	0.64±0.11	0.74±0.11	0.66±0.10	0.63±0.11

Fonte: Jonas Mendonça Targino, 2019

Ao analisar o desempenho das técnicas baseadas em modelo com classificador KNN utilizando a decomposição LL nível 3 foi possível perceber melhores resultados com a técnica SSIMGL para os quatro grupos da base AR. De modo que os melhores resultados foram alcançados nos grupos AR#2 e AR#3 para as três técnicas baseadas em modelo. Em que é possível perceber ganhos significativos de 42.75%, 49.75%, 18.84% e 66.50% para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente com a técnica SSIMGL. Percebendo maior ganho pela técnica SSIMGL no grupo AR#4. Também é interessante analisar comportamentos bem próximos das técnicas baseadas em SRC, de modo que a SRC GL quando comparada ao SRC GP não apresentou percentuais de diferença de acurácia maior que 3% entre as duas técnicas. A Figura 81 ilustra tal comportamento.

Figura 81 – Acurácia das técnicas baseadas em modelo com classificador KNN com coeficientes de aproximação do nível 3 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Enquanto ao utilizar o nível 2 de decomposição, a técnica SSIMGL apresentou melhores resultados de taxa de acurácia em 3 dos 4 grupos da base AR, de modo que a técnica SSIMGL conseguiu quase 4% a mais de taxa de acurácia no grupo AR#4 ao utilizar o nível 2, conforme ilustra a Figura 82.

Figura 82 – Acurácia das técnicas baseadas em modelo com classificador KNN com coeficientes de aproximação do nível 2 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Com classificador KNN e nível 1 de decomposição foi possível perceber que não houve ganho de performance ao aumentar o número de características de modo que todas as três técnicas baseadas em modelo apresentaram resultados inferiores quando comparada com os resultados obtidos com nível 2 de decomposição com o mesmo classificador. Tais resultados podem ser confirmados com o auxílio da Figura 83.

Figura 83 – Acurácia das técnicas baseadas em modelo com classificador KNN com coeficientes de aproximação do nível 1 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Resultados superiores aos apresentados com KNN, são perceptíveis com classificador ELM. Em que a ELM obteve ganhos de acurácia de 47.07%, 40.08 %, 45.49% e 47.29% respectivamente para os grupos AR#1, AR#2, AR#3 e AR#4 utilizando o nível 3 de decomposição com a técnica SSIMGL. Enquanto as técnicas SRC GP e SRC apresentaram resultados de acurácia muito próximos, de modo que a técnica SRC GL obteve resultados um pouco melhores em que os mesmos não ultrapassaram 3% de acurácia superior a técnica SRC GP. Tais resultados podem ser visualizados com o auxílio da Figura 84.

Figura 84 – Acurácia das técnicas baseadas em modelo com classificador ELM com coeficientes de aproximação do nível 3 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Enquanto ao utilizar o nível 2 de decomposição da TW com classificador ELM a técnica SSIMGL novamente conseguiu as melhores taxas de reconhecimento, entretanto nos grupos AR#2 e AR#3 houve uma queda de performance de 96% para 95.75% e 97% para 96.33% nos respectivos grupos, conforme ilustra a Figura 85. Enquanto nos grupos AR#1 e AR#4 houve ganho de performance de 93.92% para 95.17% e 91.50%

para 94.17%. Podendo perceber tais ganhos de performances nos grupos com maiores variações de iluminação como também aumento do tamanho da oclusão.

Figura 85 – Acurácia das técnicas baseadas em modelo com classificador ELM com coeficientes de aproximação do nível 2 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Novamente a técnica SSIMGL apresentou resultados superiores as técnicas SRC GP e SRC GL ao utilizar nível 1 de decomposição com TW. De modo que não houve ganho significativo ao utilizar o nível 1 de decomposição em relação ao nível 2. Em que percebemos resultados próximos de taxa de reconhecimento. Significando-se que o nível 2 apresenta-se muito representativo quando comparado ao nível 1 de decomposição da TW. A Figura 86 ilustra os resultados de acurácia dos métodos baseados em modelo ao utilizar o nível 1 de decomposição.

Figura 86 – Acurácia das técnicas baseadas em modelo com classificador ELM com coeficientes de aproximação do nível 1 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Ao utilizar o classificador SVM com nível 3 de decomposição da TW nos quatro grupos da base AR percebemos consideráveis percentuais de acurácia da técnica SSIMGL, apresentando resultados superiores as demais técnicas baseadas em modelo. Obtendo ganhos de reconstrução de 31.33%, 25.75%, 3.83% e 22.00% respectivamente nos grupos

AR#1, AR#2, AR#3 e AR#4 com a técnica SSIMGL. Um fato interessante do classificador SVM nesses conjuntos é que ao lidar com oclusões de óculos no grupo AR#3, mesmo com a base ocluída nesse grupo ele conseguiu 92.83% de acurácia, conforme a Figura 87.

Figura 87 – Acurácia das técnicas baseadas em modelo com classificador SVM com coeficientes de aproximação do nível 3 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Paralelamente ao utilizar o nível 2 da TW com classificador SVM foi possível obter ganhos de performance quando comparada ao SVM com nível 3 de decomposição com os grupos AR#1 e AR#4 utilizando a técnica SSIMGL como base, sendo a técnica que apresentou melhores resultados. Enquanto no grupo AR#2 a performance manteve-se contínua. Já no grupo AR#3 teve-se uma pequena queda de performance de 96.66% para 96.50%. Tais resultados podem ser visualizados com o auxílio da Figura 88.

Figura 88 – Acurácia das técnicas baseadas em modelo com classificador SVM com coeficientes de aproximação do nível 2 da TW nos grupos da base AR

Fonte: Jonas Mendonça Targino, 2019

Paralelamente ao utilizar o nível 2 da TW com classificador SVM foi possível obter ganhos de performance quando comparada ao SVM com nível 3 de decomposição com os grupos AR#1 e AR#4 utilizando a técnica SSIMGL como base, sendo a técnica que apresentou melhores resultados. Enquanto no grupo AR#2 a performance manteve-se

contínua. Já no grupo AR#3 teve-se uma pequena queda de performance de 96.66% para 96.50%. Tais resultados podem ser visualizados com o auxílio da Figura 88.

Enquanto ao utilizar o nível 1 de decomposição da TW com classificador SVM, ao analisar a técnica SSIMGL foram obtidos ganhos apenas nos grupos AR#2 e AR#3, obtendo ganhos de 0.50% e 0.16% nos respectivos grupos. Enquanto nos grupos AR#1 e AR#4 teve queda de performance de 0.42% e 0.16% respectivamente, conforme ilustra a Figura 89.

Figura 89 – Acurácia das técnicas baseadas em modelo com classificador SVM com nível 1 de decomposição da TW nos quatro grupos presentes na base AR

Fonte: Jonas Mendonça Targino, 2019

Ao analisar o ganho ao utilizar os níveis de decomposição 1, 2 e 3 percebe-se que com a avaliação com classificador KNN o nível 3 de decomposição representa muito bem todo o conjunto de modo que não há ganho significativo ao utilizar os níveis 1 e 2. A Figura 90 ilustra os ganhos das técnicas baseadas em modelo ao se utilizar os três níveis de decomposição da TW com classificador KNN.

Figura 90 – Ganho das técnicas baseadas em modelo ao utilizar os níveis 1 e 2 de decomposição da TW com classificador KNN

Fonte: Jonas Mendonça Targino, 2019

Enquanto ao avaliar cada técnica com classificador ELM nos três níveis de decomposição percebe-se ganho significativo ao utilizar os níveis 1 e 2 apenas para a base ocluída.

Enquanto para as técnicas baseadas em modelo existe baixo ganho ao utilizar os níveis 1 e 2. A Figura 91 ilustra o ganho das técnicas baseadas em modelo após utilizar os três níveis de decomposição com TW.

Figura 91 – Ganho das técnicas baseadas em modelo ao utilizar os níveis 1 e 2 de decomposição da TW com classificador ELM

Fonte: Jonas Mendonça Targino, 2019

Resultados similares aos resultados dos ganhos com ELM podem ser visualizados com o classificador SVM utilizando os níveis 2 e 3 de decomposição conforme ilustra a Figura 92, em que é possível visualizar maior ganho apenas ao se avaliar a base oculta. Induzindo-se que o nível 3 de decomposição apresenta boa representatividade de todo o conjunto.

Figura 92 – Ganho das técnicas baseadas em modelo ao utilizar os níveis 1 e 2 de decomposição da TW com classificador SVM

Fonte: Jonas Mendonça Targino, 2019

Quando é realizada uma análise sobre as técnicas de reconstrução também é interessante analisar o erro por classe dessa técnica, de modo a analisar qual indivíduo o classificador errou mais, como também verificar qual indivíduo o classificador julgou ser

erroneamente. Tais análises são interessantes de modo a conhecer características similares entre tais indivíduos.

Ao se analisar o erro por classe da técnica SRC GP foram visualizadas maiores variações nos grupos AR#1 e AR#4, conforme a Figura 93. De modo que nos grupos AR#2 e AR#3 foram visualizados menores erros por classe.

Figura 93 – Distribuição das taxas de erro geradas pela técnica SRC com Grafo de Poisson na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Paralelamente a técnica SRC GL apresentou maiores erros por classe nos grupos AR#1 e AR#4 conforme a Figura 94. Dessa forma obtendo os menores erros por classe nos grupos AR#2 e AR#3, em que a oscilação de erros por classe é reduzida.

Figura 94 – Distribuição das taxas de erro geradas pela técnica SRC com Grafo Laplaciano na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Ao analisar as taxas de erros por classe da técnica SSIMGL é possível perceber baixas taxas de erro em todos os quatro grupos da base AR, entretanto os melhores

resultados foram conseguidos com os grupos AR#2 e AR#3. Embora para os dois outros grupos da base AR os resultados também tenham sido equivalentes as outras técnicas apresentadas neste trabalho. Tais resultados estão dispostos com o auxílio da Figura 95.

Figura 95 – Distribuição das taxas de erro geradas pela técnica SSIMGL na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Ao analisar o erro por classe das três técnicas baseadas em modelo conforme a Figura 96 é possível perceber os melhores resultados com a técnica SSIMGL, seguidamente da técnica SRC GL. A técnica SSIMGL apresentou menores erros por classe em todos os grupos da base AR, apresentando os menores erros nos grupos AR#2 e AR#3.

Figura 96 – Erros por classe das três técnicas baseadas em modelo nos quatro grupos presentes na base AR com classificador ELM e nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Ao avaliar as classes que apresentaram maiores taxas de erro com a técnica SRC GP visualizou-se que as classes 58, 22, 55 e 58 apresentaram maiores taxas de erro sendo confundidas respectivamente na maioria das vezes pelas classes 45, 45, 77 e 59 nos grupos AR#1, AR#2, AR#3 e AR#4 nessa mesma ordem, conforme apresentado na Figura 97.

Figura 97 – Classes que apresentaram maior erro para cada grupo da base AR, como também os indivíduos confundidos após classificação com ELM para a técnica SRC GP

Fonte: Jonas Mendonça Targino, 2019

Após analisar os resultados obtidos com o classificador ELM foi possível perceber que a técnica SRC GL apresentou maiores confusões por classe nos indivíduos 22, 22, 55 e 58, confundindo-os com os indivíduos 45, 45, 77 e 31 respectivamente para os grupos AR#1, AR#2, AR#3 e AR#4, conforme ilustra a Figura 98. Nessas confusões feitas pelo classificador pode-se perceber a olho nu um certo grau de semelhança entre as imagens.

Figura 98 – Classes que apresentaram maior erro para cada grupo da base AR, como também os indivíduos confundidos após classificação com ELM para a técnica SRC GL

Fonte: Jonas Mendonça Targino, 2019

Na Figura 99 é possível visualizar quais classes apresentaram maiores taxas de erro para a técnica SSIMGL mediante classificação com ELM. Com o auxílio dessa mesma Figura visualiza-se com quais classes foram confundidas na maioria das vezes. Em que as classes 7, 6, 37 e 77 foram confundidas respectivamente com as classes 45, 17, 45 e 35 nos grupos AR#1, AR#2, AR#3 e AR#4 nessa ordem.

Figura 99 – Classes que apresentaram maior erro para cada grupo da base AR, como também os indivíduos confundidos após classificação com ELM para a técnica SSIMGL

Fonte: Jonas Mendonça Targino, 2019

Ao se analisar a técnica SRC GP tomando por base algumas métricas de desempenho pode-se chegar aos resultados que estão dispostos na Tabela 16. Percebendo os maiores valores de F1-score e MCC nos grupos AR#2 e AR#3.

Tabela 16 – Métricas de desempenho da técnica SRC GP nos quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-score	MCC
AR#1	0.7100	0.7706	0.7177	0.7261
AR#2	0.8350	0.8731	0.8297	0.8399
AR#3	0.8433	0.8878	0.8455	0.8539
AR#4	0.5817	0.7226	0.6085	0.6193

Fonte: Jonas Mendonça Targino, 2019

Resultados das métricas de desempenho um pouco melhores do que o SRC GP, são apresentados com a técnica SRC GL. Os quais são apresentados na Tabela 17, percebendo os mais baixos valores de F1-Score, MCC e precisão nos grupos AR#1 e AR#4.

Enquanto a técnica SSIMGL apresentou os melhores resultados de acurácia, precisão, F1-score e MCC para os quatro grupos da base AR. Conseguindo taxas maiores que 91%

Tabela 17 – Métricas de desempenho da técnica SRC GL nos quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-score	MCC
AR#1	0.7275	0.7877	0.7359	0.7440
AR#2	0.8475	0.8830	0.8461	0.8541
AR#3	0.8617	0.8984	0.8618	0.8695
AR#4	0.5983	0.7314	0.6138	0.6357

Fonte: Jonas Mendonça Targino, 2019

para todas as métricas de desempenho em todos os grupos da base AR. Tais resultados podem ser consultados com o auxílio da Tabela 18.

Tabela 18 – Métricas de desempenho da técnica SSIMGL nos quatro grupos da base AR

Grupos	Acurácia	Precisão	F1-score	MCC
AR#1	0.9392	0.9475	0.9393	0.9408
AR#2	0.9600	0.9683	0.9594	0.9614
AR#3	0.9700	0.9740	0.9698	0.9706
AR#4	0.9150	0.9359	0.9140	0.9189

Fonte: Jonas Mendonça Targino, 2019

As curvas de FAR e FRR da técnica Representação Esparsa com Grafo de Poisson apresentou pontos EER um pouco mais baixos de que algumas técnicas baseadas em subespaço. Isso, sendo um bom fator a julgar uma técnica. Pois quanto mais baixo é o ponto EER, menor é aceitação de impostores e também menores são os percentuais de falsas rejeições. Os pontos de cruzamento das duas curvas foram 0.28, 0.34, 0.28 e 0.33 para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Na Figura 100 são apresentadas as curvas e os pontos EER para os quatro grupos presentes na base AR.

Figura 100 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SRC juntamente com grafo de Poisson

Fonte: Jonas Mendonça Targino, 2019

Ao analisar as curvas de FAR e FRR das técnicas baseadas em modelo pode-se perceber com o auxílio da Figura 101, pontos de cruzamento EER um pouco mais baixos que o da técnica SRC com grafo de Poisson. Esses valores baixos no ponto EER significam um bom sinal. Representando ser uma melhor técnica. Os pontos de EER são 0.26, 0.35, 0.28 e 0.32 para os grupos AR#1, AR#2, AR#3 e AR#4 respectivamente. Esses sendo os pontos ótimos de valores da taxa para essa técnica nos quatro grupos da base AR.

Figura 101 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SRC com grafo Laplaciano

Fonte: Jonas Mendonça Targino, 2019

Após a verificação do erro por classe da técnica SSIMGL, é interessante analisar o comportamento das curvas de FAR e FRR. A técnica SSIMGL apresentou bons resultados em termos de performance e ganho ao se reconstruir a imagem. Na Figura 102 são apresentadas as curvas de FAR e FRR de acordo com cada grupo da base AR. As duas curvas tiveram taxas de semelhanças iguais nos pontos 0.65, 0.78, 0.72 e 0.5, esses pontos sendo os pontos de cruzamento das duas curvas. Garantindo que esse é o limiar ótimo de classificação. De modo que valores acima desse limiar permitem uma maior quantidade de rejeições de indivíduos da base, e valores abaixo desse limiar permitem uma maior quantidade de aceitações de pessoas não autorizadas (impostores) no sistema.

Figura 102 – Curva com a taxa de falsa aceitação versus taxa de falsa rejeição alcançada pela técnica SSIMGL

Fonte: Jonas Mendonça Targino, 2019

Diante dos pontos definidos para os grupos da base AR, aplicou-se tais limiares nos conjuntos de forma a identificar os comportamentos de performance das técnicas baseadas em modelo na tarefa de reconstrução. Dessa forma foi verificado que apenas nos grupos AR#1 e AR#4 que as técnicas tiveram uma pequena queda de performance. A técnica que apresentou maiores variações foi a SSIMGL, sendo 1.09% e 2.50% nos respectivos grupos. Tal comportamento pode ser visualizado com o auxílio da Tabela 19.

Tabela 19 – Análise da taxa de reconhecimento das técnicas baseadas em modelo após aplicação do limiar EER com classificador ELM

Grupo	SRC GP		SRC GL		SSIMGL	
	Normal	Com EER	Normal	Com EER	Normal	Com EER
AR#1	71.00%	71.00%	72.75%	72.66%	93.92%	92.83%
AR#2	83.50%	83.50%	84.75%	84.75%	96.00%	96.00%
AR#3	84.33%	84.33%	86.16%	86.16%	97.00%	97.00%
AR#4	58.16%	57.16%	59.83%	59.16%	91.50%	89.00%

8.3.2 Resultados nos grupos da base Yale

Tomando por base as reconstruções das imagens dos dois grupos da base Yale com as técnicas baseadas em modelo. Na Figura 103 são apresentadas 8 imagens de 4 indivíduos com oclusões em cada grupo. Com o auxílio da Figura é possível perceber melhores qualidades das imagens reconstruídas com a técnica SSIMGL.

Figura 103 – Imagens reconstruídas com as técnicas baseadas em modelo nos dois grupos da base Yale

Fonte: Jonas Mendonça Targino, 2019

Uma análise interessante é que a técnica SSIMGL apresentou os melhores resultados de RMSE para o grupo Yale#1 e os mais altos valores de RMSE no grupo Yale#2. Conforme pode ser visto na Tabela 20.

Tabela 20 – Resultados de RMSE das técnicas baseadas em modelo nos grupos da base Yale

Técnica	RMSE	
	Yale#1	Yale#2
	média $\pm$ desvio	média $\pm$ desvio
SRC GP	55.92 $\pm$ 10.85	52.44 $\pm$ 15.17
SRC GL	55.92 $\pm$ 10.85	52.44 $\pm$ 15.17
SSIMGL	55.01 $\pm$ 9.16	54.67 $\pm$ 11.50

Resultados similares ao RMSE podem ser visualizados com análise do PSNR para as três técnicas. Tais resultados podem ser consultados com o auxílio da Tabela 21.

Tabela 21 – Resultados de PSNR das técnicas baseadas em subespaço nos grupos da base Yale

Técnica	PSNR	
	Yale#1	Yale#2
	média $\pm$ desvio	média $\pm$ desvio
SRC GP	13.34 $\pm$ 1.80	14.26 $\pm$ 3.56
SRC GL	13.34 $\pm$ 1.80	14.26 $\pm$ 3.56
SSIMGL	13.44 $\pm$ 1.57	13.53 $\pm$ 1.69

Tais considerações se repetem ao se analisar a métrica SSIM, em que a técnica SSIMGL apresentou melhores resultados no SSIM no grupo Yale#1, enquanto no grupo Yale#2 as técnicas SRC GP e SRC GL apresentaram os mais altos valores de SSIM.

Tabela 22 – Resultados de SSIM das técnicas baseadas em modelo nos grupos da base Yale

Técnica	SSIM	
	Yale#1	Yale#2
	média $\pm$ desvio	média $\pm$ desvio
SRC GP	0.46 $\pm$ 0.07	0.50 $\pm$ 0.12
SRC GL	0.46 $\pm$ 0.07	0.50 $\pm$ 0.12
SSIMGL	0.47 $\pm$ 0.06	0.47 $\pm$ 0.06

Com a inserção das oclusões artificiais na base de dados Yale foi possível mensurar como as técnicas baseadas em modelo reagiram perante o conjunto. Na Figura 104 são apresentados os resultados com os classificadores ELM, KNN e SVM.

Figura 104 – Acurácia das técnicas baseadas em modelo com nível 3 de decomposição da TW nos grupos da base Yale com os classificadores ELM, KNN e SVM

Fonte: Jonas Mendonça Targino, 2019

8.4 Comparação das melhores técnicas

De maneira a analisar o comportamento das técnicas foi verificado que as técnicas SSIMGL e SRC *Fast Rec PCA* apresentaram os melhores resultados de reconstrução, visto que a primeira é baseada em modelo e a segunda em subespaço. Sendo que a primeira técnica apresentou resultados mais robustos independentemente do tipo de oclusão. As Figuras 105 e 106 ilustram o comportamento de todas as técnicas com os quatro grupos da base AR perante os classificadores KNN, ELM e SVM.

Ao analisar as Figuras 105 e 106 visualiza-se que a técnica SSIMGL apresentou melhores resultados nos quatro grupos da base AR, atuando como uma técnica que apresenta baixo grau de sensibilidade aos mais diversos tipos de variações presentes no ambiente. Conseguindo obter taxa de erro igual a 6.08%, 4%, 3% e 8.5% respectivamente nos grupos AR#1, AR#2, AR#3 e AR#4, ao ser avaliada com classificador ELM e nível 3 de decomposição da TW. Enquanto a técnica SRC *Fast Rec PCA* também demonstrou bons resultados, obtendo taxa de erro 11.67%, 5.25%, 3.67% e 17% nessa ordem nos grupos AR#1, AR#2, AR#3 e AR#4 também avaliada com ELM utilizando nível 3 de decomposição da TW, podendo perceber maiores taxas de erro nos grupos com maiores variações presentes no ambiente.

Mediante os resultados é possível perceber elevados percentuais de contribuição das técnicas, tomando como base a técnica SSIMGL pode-se visualizar ganhos em termos de acurácia ao se reconstruir, obtendo 47.07%, 40.08%, 45.49% e 47.29% de ganhos de reconstrução respectivamente nos grupos AR#1, AR#2, AR#3 e AR#4 com classificador ELM e nível 3 de decomposição da transformada Wavelet.

Figura 105 – Análise comparativa de todas as técnicas de reconstrução nos grupos AR#1 e AR#2 com os classificadores KNN, ELM e SVM utilizando nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

Uma análise interessante é que o SVM obteve melhores resultados quando apresentado ao grupo AR#4, ou seja, o SVM demonstrou maior insensibilidade do que outros classificadores quando apresentado a imagens com maiores percentuais de oclusão. Obtendo com a técnica SSIMGL ganhos de 2% e 14.17% respectivamente quando comparado aos classificadores ELM e KNN no grupo AR#4.

Buscando analisar os tipos de erros das técnicas de reconstrução bem como também qual a melhor técnica a qual permite alta acurácia, baixo percentual de falsos positivos e baixo percentual de falsos negativos, foram analisadas as curvas ROC das técnicas com classificador ELM. Dessa forma estão dispostas na Figura 107 a média das curvas ROC das 100 classes da base AR de acordo com cada grupo.

Enquanto ao analisar a curva ROC da melhor classe (classe que o classificador apresentou maior acurácia) de cada técnica pode-se perceber curvas com área sobre a curva ROC de valor 1 para quase todas as técnicas, conforme a Figura 108, paralelamente

Figura 106 – Análise comparativa de todas as técnicas de reconstrução nos grupos AR#3 e AR#4 com os classificadores KNN, ELM e SVM utilizando nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

podendo visualizar que as técnicas que apresentaram maiores sensibilidades foram as técnicas Fisherfaces e FRPCA conforme os grupos AR#1, AR#2 e AR#4.

Já ao avaliar a curva ROC da pior classe (classe que o classificador apresentou menor acurácia) de cada técnica, foi possível perceber maiores sensibilidades apresentadas pelas técnicas Fisherfaces, FRPCA e E APCA para os quatro grupos da base AR, conforme ilustra a Figura 109. De modo que é possível visualizar maiores sensibilidades no grupo AR#4 com as técnicas Fisherfaces e APCA. Enquanto as técnicas SSIMGL e SRC com *Fast Recursive* PCA apresentaram consideráveis resultados perante as demais técnicas de reconstrução nos quatro grupos da base.

Figura 107 – Curvas ROC média das técnicas de reconstrução em cada grupo da base AR com classificador ELM

Fonte: Jonas Mendonça Targino, 2019

8.5 Teste estatístico de Wilcoxon

Como forma de confirmar de maneira estatística qual técnica apresentou melhores resultados, foi realizado um teste estatístico de forma a complementar os resultados das taxas de acurácia, como também métricas de validação da imagem. Para esse propósito, foi utilizado o teste de Wilcoxon (LITCHFIELD; WILCOXON, 1949) como teste de hipótese. Esse teste é um método não paramétrico para análise de duas amostras pareadas.

Esse teste foi analisado como forma de analisar qual técnica apresenta melhor resultado de identificação perante a tarefa de reconstrução de faces e com isso tentar analisar possíveis sobreposições de suas distribuições. Esse teste objetivou analisar a hipótese nula, em que esta tinha como base que as distribuições dos valores da melhor técnica de reconstrução daquele conjunto eram iguais as amostras das outras técnicas. Nesse teste as amostras continham as taxas de acurácia de cada técnica mediante classificação com ELM, de modo que para cada configuração de parâmetros a ELM foi rodada 10

Figura 108 – Curva Roc da melhor classe para cada técnica de reconstrução em cada grupo da base AR com classificador ELM

Fonte: Jonas Mendonça Targino, 2019

vezes. Dessa forma gerou-se um vetor de distribuições por cada técnica e esse vetor foi comparado com a ajuda do teste estatístico de Wilcoxon.

Para verificação da hipótese nula, selecionou-se a técnica que apresentou maior acurácia para os quatro grupos da base AR, e comparou-se essa técnica com todas as outras técnicas de reconstrução de faces. Para realizar essa comparação coletou-se as amostras das execuções de cada técnica com o classificador ELM, utilizando como nível de significância (α) igual a 0.05. Dessa forma um p-valor menor que α significa que a hipótese nula é rejeitada, chegando à conclusão que as técnicas comparadas apresentam distribuições diferentes.

Com a comparação visualizou-se que a técnica SSIMGL realmente foi a técnica que apresentou os melhores resultados, rejeitando a hipótese nula para todas as outras técnicas.

Figura 109 – Curva Roc da pior classe para cada técnica de reconstrução em cada grupo da base AR com classificador ELM

Fonte: Jonas Mendonça Targino, 2019

8.6 Resumo dos experimentos

Nesse trabalho foram apresentadas algumas técnicas presentes na literatura, durante a implementação das mesmas enxergou-se a possibilidade de desenvolvimento de outras técnicas objetivando melhores resultados em termos de reconstrução das imagens ocluídas. Dada tal possibilidade, juntamente com este estudo comparativo de técnicas foram desenvolvidas três técnicas (uma baseada em subespaço, e duas baseadas modelo). De modo que duas das três técnicas apresentaram resultados superiores de performance ao serem comparadas com técnicas presentes no estado da arte.

Com os experimentos realizados verificou-se que as técnicas baseadas em modelo apresentam melhores resultados de reconstrução do que as técnicas baseadas em subespaço. Sendo possível perceber que a SRC é uma boa técnica para analisar imagens similares, entretanto, essa técnica quando aplicada a imagens coletadas sobre ambientes não controlados exige o complemento de outra técnica (neste trabalho foram utilizadas as técnicas SSD, KNN e SSIM) com vistas a analisar a similaridade entre os pixels da imagem, tentando obter um indivíduo com maior grau de fidelidade para com a imagem de consulta.

A técnica SRC com *Fast Recursive* PCA é uma boa combinação quando aplicada aos mais diversos tipos de ambiente. Tendo uma pequena queda de performance quando

aplicada a ambientes não colaborativos com alto percentual de oclusão e variações de iluminação, por isso, as técnicas SRC com *Fast Recursive PCA* e SRC com Grafo Laplaciano apresentaram menores percentuais de reconhecimento nos grupos AR#1 e AR#4.

Também foi visto que a similaridade estrutural é uma ótima técnica para identificar faces independente do ambiente ser controlado ou não, visto que a SSIM se adapta muito bem aos mais variados ambientes. Acredita-se que uma técnica ainda melhor de detecção da parte ocluída elevaria a performance dessa técnica ainda mais, tal afirmação se deve ao fato de algumas partes do cachecol no grupo AR#4 não terem sido detectadas pela técnica de detecção da parte ocluída. Essas partes não foram detectadas como oclusão devido apresentarem altos níveis de iluminação, confundindo a técnica de detecção com a parte não ocluída.

8.7 *Prós e contras das técnicas*

Tomando por base alguns conhecimentos obtidos durante a elaboração deste trabalho foi possível elencar alguns prós e contras das técnicas de reconstrução de faces baseadas em modelo e subespaço.

8.7.1 Técnicas baseadas em subespaço

Prós:

1. apresentam melhores resultados quando aplicadas a baixos níveis de oclusão como afirma Zuo, Wang e Zhang (2009);
2. reconstruir as imagens e completar apenas os pixels não ocluídos é uma ótima estratégia e proporciona melhorias junto a taxa de reconhecimento;
3. são indicadas quando lidamos com pequeno número de indivíduos;

Contras:

1. precisam de uma quantidade considerável de imagens por indivíduo para realizar a reconstrução;
2. apresentam queda de performance quando apresentadas a altos níveis de oclusões;
3. necessidade de dados muito bem representativos;

4. Quando confrontada com altos níveis de oclusões as técnicas que não utilizam a substituição dos pixels ocluídos pelos pixels da imagem reconstruída apresentam inserção de pixels ruidosos.
5. necessita de uma boa técnica para detecção da parte ocluída na imagem da face;
6. a depender do tamanho da oclusão essas técnicas apresentam dificuldades de reconstrução;
7. Ao aumentar-se o número de indivíduos para geração do espaço de faces, pior é qualidade da imagem reconstruída.

8.7.2 Técnicas baseadas em modelo

Prós:

1. possuem relação direta com as imagens, sendo modelado com tal finalidade;
2. apresentam melhores qualidades de imagens reconstruídas, implicando consequentemente no aumento de performance;
3. são insensíveis ao número de indivíduos presente na base;
4. Apresentam maior grau de fidelidade frente a imagem reconstruída.

Contras:

1. construção do modelo é um pouco mais complicada e trabalhosa;
2. imagens com alta resolução são desejáveis de forma a garantir melhores resultados;
3. necessitam de uma boa técnica de detecção da parte ocluída;
4. necessitam de uma técnica que favoreça realizar uma pré-identificação antes de realizar a reconstrução.

8.8 Limitações de algumas técnicas

Uma peculiaridade dos métodos baseados em subespaço é o número de indivíduos para geração do espaço de faces. Isso é um dos grandes problemas dessas técnicas, pois quanto maior o número de indivíduos para geração do espaço de faces maior é a dificuldade encontrada pela técnica para reconstrução. Além disso, quando a imagem é coletada mediante ambientes não controlados maior é a inserção de ruído na imagem

reconstruída. É possível perceber com o auxílio da Figura 110 o comportamento da SSIM das imagens reconstruídas ao se aumentar o número de indivíduos para geração do espaço de faces. Portanto, quanto maior a quantidade de indivíduos para geração do espaço de faces pior é a qualidade da imagem reconstruída.

Essas técnicas enfrentam limitação da quantidade indivíduos para geração do espaço de faces, visto que quanto maior o número de indivíduos para geração do espaço de faces menor é a generalização das imagens reconstruídas. As técnicas baseadas subespaço apresentam melhores resultados com uma quantidade limitada (entre 5 e 20) de indivíduos para formação do espaço de faces.

Figura 110 – Comportamento da SSIM do conjunto ao se aumentar o número indivíduos para geração do espaço de faces

Fonte: Jonas Mendonça Targino, 2019

De maneira a analisar o comportamento das técnicas baseadas em subespaço foram gerados alguns grupos de 10 indivíduos para geração do espaço de faces. Dois exemplos de reconstruções estão dispostos na Figura 111. Um dos exemplos é advindo da base AR e o outro da base Yale.

Figura 111 – Imagens reconstruídas com as técnicas baseadas em subespaço com espaço de faces gerado a partir das faces de 10 indivíduos

Fonte: Jonas Mendonça Targino, 2019

Na Figura 112 é possível perceber a importância do percentual de representatividade do conjunto para geração do espaço de faces. Visualizando-se que um considerável limiar de reconstrução em termos de acurácia e PSNR estão localizados entre os percentuais 80% e 95%, lembrando-se que ao inserir 95% de percentual de representatividade ao reconstruir imagens com altos níveis de oclusão ou iluminação são inseridos inúmeros ruídos que podem prejudicar a tarefa de classificação e influenciar o erro do classificador. Pode-se perceber esse fenômeno na linha dois da Figura 112.

Figura 112 – Importância do percentual de representatividade do conjunto

Fonte: Jonas Mendonça Targino, 2019

Objetivando analisar como o percentual de representatividade influencia no processo de reconstrução variou-se esse percentual entre 50% e 95% nos quatro grupos da base AR. Percebendo-se que 95% é o melhor percentual de representatividade do conjunto ao reconstruir faces parcialmente ocluídas. A Figura 113 ilustra a taxa de acurácia das três melhores técnicas baseadas em subespaço ao se variar a taxa de representação do conjunto. Um dos motivos da técnica *Gappy PCA* iniciar com taxas de reconhecimento baixas deve-se ao fato dessa técnica não substituir os pixels não ocluídos da imagem original na imagem reconstruída. Como também, percentuais de representação abaixo

70% aproximam-se da imagem média do conjunto, e isso favorece a queda de performance da técnica de reconstrução.

Figura 113 – Importância do percentual de representatividade na tarefa de reconstrução de faces após avaliação com classificador ELM e nível 3 de decomposição da TW

Fonte: Jonas Mendonça Targino, 2019

8.8.1 *Asymmetrical PCA*

É interessante apresentar um dos motivos da técnica APCA não apresentar bons resultado de reconstrução dado que ela trabalha com dois espaços de faces para reconstrução da face parcialmente ocluída. Essa qualidade de reconstrução não promissora se deve a técnica original utilizar apenas imagens do mesmo indivíduo para geração do espaço de faces, de modo que essas imagens não apresentam variações de iluminação, pose e expressão. Com isso, ao aumentar o espaço de faces com faces de outros indivíduos a técnica apresenta queda de performance de reconstrução, como também de reconhecimento. A Figura 114 ilustra uma qualidade considerável de reconstrução da técnica APCA, de modo que essas imagens foram reconstruídas com faces sem variação de iluminação e pose, dado que o espaço de faces foi gerado com as imagens de apenas um indivíduo.

Figura 114 – Reconstrução com APCA, com o espaço de faces gerado por apenas um indivíduo (o mesmo da reconstrução) com imagens sem variação de iluminação e pose.

Fonte: Jonas Mendonça Targino, 2019

8.8.2 *Fast Robust PCA*

Uma das grandes limitações dessa técnica é sua estratégia para detecção da parte ocluída, a qual se apresenta não tão eficaz como muitas outras técnicas para detecção da parte ocluída, pois ela não consegue detectar todas as regiões ocluídas. Com isso é esperado que essa técnica ao utilizar outra estratégia para detecção da parte ocluída venha a possibilitar melhores qualidades das imagens reconstruídas.

Entretanto é visto que ao utilizar outra técnica para detecção da parte ocluída o algoritmo *Fast Robust PCA* apenas terá como objetivo gerar pequenas quantidades de amostras dos pixels do conjunto de treinamento com iniciativas a tentar reconstruir a imagem da face a partir de espaços de faces gerados com o auxílio das subamostras e com isso analisar se existem melhorias ou não da técnica ao se utilizar tal estratégia.

Logo, o grande problema dessa técnica é sua instabilidade em termos de detecção da oclusão.

8.8.3 Fisherfaces

Essa técnica apresenta resultados piores de reconstrução quando comparada a outras técnicas, salvo que ao trabalhar com ambientes não controlados com variações de oclusões e iluminação, o Fisherfaces apresenta péssimos resultados de reconstrução. Alguns estudos como os de Nasution, Bayu e Miura (2014) e Yi, Yang e Kim (2000) confirmam que a técnica Fisherfaces quando apresentada a ambientes não controlados sofre queda de performance. Tal fato se deve as imagens apresentarem grandes variações intraclasses, e isso impede uma boa atuação do Fisherfaces frente a reconstrução da imagem.

8.8.4 *Gappy* PCA

A técnica *Gappy* PCA é uma técnica para reconstrução de faces parcialmente ocluídas. Essa técnica vem apresentando resultados consideráveis de reconstrução, entretanto, essa técnica apresentaria resultados ainda melhores, caso realizasse a troca dos pixels não ocluídos da imagem reconstruída pelos pixels não ocluídos da imagem original (com oclusão).

Realizando o processo similar a técnica *Recursive* PCA e *Fast Recursive* PCA, as quais realizam a minimização do coeficiente e cada iteração realizam a troca do pixels não ocluídos pelos pixels da imagem de consulta.

8.8.5 Representação Esparsa

A representação esparsa é uma ótima técnica para identificação do indivíduo antes de realizar a reconstrução. Logo, quando aplicada a ambientes não controlados exige-se outra técnica (nas técnicas aqui implementadas utilizou-se SSD, KNN e SSIM) para auxiliar junto a classificação do indivíduo com maior semelhança.

Uma das desvantagens dessa técnica é que caso ela não atribua um alto valor de correlação as imagens do indivíduo correto, todo o processo a frente é comprometido, podendo vir a ocasionar uma reconstrução com baixa qualidade, substituição de pixels feitos erroneamente e consequentemente baixa performance de identificação.

8.9 *Considerações finais do capítulo*

Nesse capítulo foram apresentados os resultados alcançados com as técnicas de reconstrução quando aplicadas a duas bases de dados. Os resultados experimentais mostraram que as técnicas SSIMGL e SRC Fast Rec PCA apresentaram os melhores desempenhos nos seis grupos de oclusões gerados.

Com base nos resultados experimentais, pode-se realizar os seguintes comentários:

- Ao realizar um estudo comparativo das técnicas baseadas em reconstrução considerando apenas as métricas de validação de imagem, pode-se obter resultados não condizentes com a realidade, visto que essas métricas são sensíveis a iluminação

presente nas imagens. Por isso que no grupo AR#2 foram obtidos os melhores valores de PSNR, RMSE e SSIM. Este grupo não apresenta variação de iluminação. Diante disso, optou-se também por analisar a acurácia no reconhecimento como forma de julgar o quão boa foi a técnica na etapa de reconstrução.

- Dentre as técnicas de subespaço descritas na literatura, a técnica *Fast Recursive PCA* é uma das mais indicadas para aplicação prática, pois apresentou bons resultados em termos de reconstrução e é bastante rápida no processo de minimização dos coeficientes da combinação linear.
- Ao lidar com reconstrução de imagens deve-se escolher adequadamente a técnica que será utilizada para detecção da parte ocluída. Caso essa oclusão não seja segmentada corretamente, o processo de reconstrução ficará comprometido, podendo aparecer ruídos na imagem reconstruída.
- A substituição dos pixels ocluídos pelos respectivos pixels na imagem reconstruída é uma boa estratégia. Esta possibilitou alcançar melhores resultados no reconhecimento e também melhorias perceptíveis visualmente na imagem reconstruída.
- Dentre as três técnicas de reconstrução propostas neste trabalho, as técnicas SSIMGL e SRC *Fast Rec PCA* apresentaram os melhores resultados para os quatro grupos da base AR independente dos classificadores utilizados. Essas técnicas também obtiveram os melhores resultados ao utilizar oclusões artificiais.
- Neste trabalho foram elaboradas Figuras para cada técnica de modo a facilitar a compreensão e abstração da sua formulação matemática, possibilitando que o leitor compreenda os passos envolvidos na sua implementação, consequentemente fornecendo um melhor entendimento da técnica.

De acordo com Collier (1993) um bom estudo comparativo pode realizar descobertas indutivas de novas hipóteses e construção de novas teorias (no nosso caso, novas técnicas). Levando em conta esta afirmação, pode-se dizer que este trabalho cumpriu todos os objetivos, visto que apresentou um estudo comparativo detalhado das técnicas baseadas em reconstrução, que possibilitou a proposição de três novas técnicas. Os resultados experimentais mostraram que estas técnicas alcançaram desempenhos melhores ou similares as técnicas descritas na literatura.

Cabe ressaltar que os algoritmos utilizados neste trabalho foram desenvolvidos na linguagem Matlab ¹ e estão disponíveis publicamente em um repositório Github que pode ser acessado pelo link <https://github.com/faizao/Artefatos_mestrado>. Neste mesmo link também podem ser visualizadas todas as imagens reconstruídas. Vale lembrar que todos os códigos serão mantidos atualizados e correções de eventuais *bugs* serão realizadas, a fim de possibilitar que a comunidade científica possa utilizá-lo para realizar futuras replicações.

¹ <https://www.mathworks.com/products/matlab.html>

9 Conclusão e perspectivas futuras

A biometria surge na sociedade como forma a tentar suprir as exigências da população por estratégias de reconhecimento de identidade que sejam menos susceptíveis a roubos, fraudes e atitudes mal intencionadas. De maneira que a biometria possibilita que o usuário seja a própria senha, possibilitando que seja possível distinguir um determinado indivíduo a partir da análise de suas características físicas ou comportamentais. Dentre as modalidades biométricas a face é uma das modalidades mais utilizadas por apresentar caráter não intrusivo e não necessitar da colaboração do usuário para a coleta de dados. Reconhecimento facial vem obtendo bons resultados quando aplicado a ambientes controlados. Entretanto, não é possível realizar a mesma afirmação quando lidamos com ambientes não controlados.

Sistemas de reconhecimento facial em ambientes de mundo real, frequentemente, lidam com condições não controladas e não previsíveis tais como grande mudança na iluminação, pose, expressão e oclusão, as quais introduzem variações intraclasse e degradam a performance do reconhecimento. Dentre os tipos de variações encontradas em ambientes não controlados a oclusão é a menos estudada. Nesse sentido, esse trabalho surge como uma iniciativa promissora para ajudar no desenvolvimento do reconhecimento facial em ambientes não controlado.

A partir dos experimentos realizados verificou-se que as técnicas de reconstrução baseadas em subespaço que realizam minimização dos coeficientes de combinação linear e realizam a troca dos pixels ocluídos pelos pixels da imagem reconstruída apresentam melhores resultados quando comparados a outras técnicas baseadas em subespaço. Estas estratégias são implementadas no *Recursive PCA* e *Fast Recursive PCA*. Com relação ao nível de decomposição da Transformada Wavelet, não houve nenhum nível que se destacasse. Por outro lado, com relação aos classificadores pode-se perceber que a ELM e SVM apresentaram alta performance ao lidar com imagens reconstruídas.

Conforme visto neste trabalho, as técnicas de reconstrução baseadas em modelo apresentam maior robustez quando aplicadas a tarefa de reconstrução de faces parcialmente ocluídas. Entretanto, as técnicas baseadas em subespaço não podem ser descartadas. Por exemplo, a técnica SRC Fast Rec PCA apresentou resultados de reconstrução bastante interessante. Sabe-se que as técnicas baseadas em subespaço possuem limitação quanto

ao número de indivíduos para geração do espaço de faces. Entretanto, quando essas técnicas são associadas a estratégias que promovem a seleção das amostras (SRC ou SSIM) mais representativas do conjunto de treinamento, essas técnicas podem alcançar ganhos significativos. Por outro lado, adotar a estratégia de substituição dos pixels ocluídos pelos pixels da imagem reconstruída é uma ótima ideia, a qual promove melhorias de performance frente a acurácia de reconhecimento.

De forma geral, as contribuições deste trabalho foram as seguintes:

- apresenta uma descrição detalhada e uma formalização matemática unificada das técnicas existentes na literatura para detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico;
- com base nos resultados dos experimentos realizados, tem-se um ponto de partida sobre quais técnicas de reconstrução e parâmetros são mais indicados para tratar com ambiente não controlado;
- proposição de três técnicas de reconstrução, sendo que uma delas foi responsável por produzir os melhores resultados.

9.1 Limitações

Uma das grandes limitações deste trabalho diz respeito a base de dados utilizada. A base de dados Yale possui um número pequeno de amostras, com oclusões bastante simples de serem tratadas. Mesmo com a inserção de oclusão artificial, o SVM foi capaz de obter uma considerável taxa de reconhecimento nos dois grupos da base Yale (oclusão artificial e natural).

Por outro lado, a base de dados AR apresenta diversas oclusões, as quais caso não sejam tratadas podem degradar o desempenho do classificador. Seria interessante se outras fossem utilizadas. No entanto, a maioria das bases de dados, semelhante a AR, são privadas ou pagas.

9.2 Perspectivas futuras

As perspectivas futuras possuem como objetivo principal incluir tópicos que não foram devidamente discutidos ao longo desta pesquisa, pelos mais diversos motivos, como

também questões que ganham importância a partir dos resultados obtidos com este estudo. Sendo elas:

- investigar o comportamento de outras técnicas baseadas em modelo e compará-las com as técnicas apresentadas neste trabalho;
- estender as técnicas apresentadas nesse trabalho e realizar combinações dessas técnicas com vistas a produzir novas técnicas e conseqüentemente melhorias na acurácia de reconhecimento;
- investigar o comportamento de outras técnicas para detecção de oclusões parciais em imagens de face;
- analisar o comportamento das Redes Neurais Convolutivas quando aplicadas ao contexto de oclusão ;
- empregar outras técnicas de extração de características, como por exemplo, Transformada Contourlet, Padrões Binários Locais, filtros de Gabor e Transformada de Fourier;
- analisar o comportamento das técnicas descritas neste trabalho em outras bases de dados com oclusões naturais.

9.3 Publicações vinculadas a dissertação

Os artigos científicos listados a seguir estão diretamente vinculados à esta dissertação e foram produzidos ao longo do desenvolvimento deste projeto de pesquisa. Os artigos serão apresentados conforme a ordem cronológica de sua elaboração.

1. *Detecção e reconstrução de oclusões parciais em imagens de face visando Reconhecimento Biométrico*, WTDSI 2017 - X Workshop de Teses e Dissertações em Sistemas de Informação (TARGINO; PERES; LIMA, 2017).
2. *Methods of detecting and reconstructing partial occlusions in face images: Systematic Literature Review*, WVC 2017 - XIII Workshop de Visão Computacional (TARGINO; PERES; LIMA, 2018b).
3. *Biometric recognition based on fingerprint: A comparative study*, WVC 2017 - XIII Workshop de Visão Computacional (DURU; TARGINO; LIMA, 2018).

4. *Técnicas baseadas em subespaço para reconstrução de faces parcialmente ocluídas: Um estudo comparativo*, COTB 2018 - IX Computer on the Beach (TARGINO; PERES; LIMA, 2018c).
5. *Técnicas de detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico*, WTDSI 2018 - XI Workshop de Teses e Dissertações em Sistemas de Informação (TARGINO; PERES; LIMA, 2018d).
6. *Estudo comparativo de técnicas baseadas em subespaço na tarefa de reconstrução de faces parcialmente ocluídas*, SBSI 2018 - Simpósio Brasileiro de Sistemas de Informação (TARGINO; PERES; LIMA, 2018a).
7. *A comparative study between deep learning and traditional machine learning techniques for facial biometric recognition*, Iberamia 2018 (FINIZOLA et al., 2018).
8. *Comparative study between Deep Face, Autoencoder and Traditional Machine Learning Techniques aiming at Biometric Facial Recognition*, IJCNN 2019 (FINIZOLA et al., 2019).

Referências¹

- AISHA, A. et al. Face recognition invariant to partial occlusions. *KSII Transactions on Internet and Information Systems (TIIS)*, v. 8, n. 7, p. 2496–2511, 2014. Citado 2 vezes nas páginas 54 e 213.
- ALYUZ, N.; GOKBERK, B.; AKARUN, L. 3-d face recognition under occlusion using masked projection. *IEEE Transactions on Information Forensics and Security*, IEEE, v. 8, n. 5, p. 789–802, 2013. Citado 2 vezes nas páginas 72 e 213.
- ALYUZ, N.; GOKBERK, B.; AKARUN, L. Detection of realistic facial occlusions for robust 3d face recognition. In: IEEE. *Pattern Recognition (ICPR), 2014 22nd International Conference on*. [S.l.], 2014. p. 375–380. Citado na página 213.
- ALYÜZ, N. et al. Robust 3d face recognition in the presence of realistic occlusions. In: IEEE. *Biometrics (ICB), 2012 5th IAPR International Conference on*. [S.l.], 2012. p. 111–118. Citado 2 vezes nas páginas 72 e 213.
- ASHIN, R.; MORIMOTO, A.; VAILLANCOURT, R. Image compression with multiresolution singular value decomposition and other methods. *Mathematical and Computer Modelling*, Elsevier, v. 41, n. 6-7, p. 773–790, 2005. Citado na página 62.
- BELHUMEUR, P. N.; HESPANHA, J. P.; KRIEGMAN, D. J. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on pattern analysis and machine intelligence*, IEEE, v. 19, n. 7, p. 711–720, 1997. Citado 3 vezes nas páginas 51, 90 e 91.
- BELLIL, W.; BRAHIM, H.; AMAR, C. B. Gappy wavelet neural network for 3d occluded faces: detection and recognition. *Multimedia Tools and Applications*, Springer, v. 75, n. 1, p. 365–380, 2016. Citado 2 vezes nas páginas 72 e 213.
- BENALIOUCHE, H.; TOUAHRIA, M. Comparative study of multimodal biometric recognition by fusion of iris and fingerprint. *The Scientific World Journal*, Hindawi, v. 2014, 2014. Citado na página 48.
- BENEZETH, Y. et al. Vision-based system for human detection and tracking in indoor environment. *International Journal of Social Robotics*, Springer, v. 2, n. 1, p. 41–52, 2010. Citado na página 55.
- BINDU, A.; KUMAR, C. R. Inpainting for big data. In: IEEE. *Signal and Image Processing (ICSIP), 2014 Fifth International Conference on*. [S.l.], 2014. p. 62–67. Citado na página 213.
- BLANZ, V.; VETTER, T. Face recognition based on fitting a 3d morphable model. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 25, n. 9, p. 1063–1074, Sept 2003. ISSN 0162-8828. Citado na página 51.
- BUCIU, I. Challenges and specifications for robust face and gait recognition systems for surveillance application. *Journal of Electrical and Electronics Engineering*, University of Oradea, v. 7, n. 1, p. 25, 2014. Citado 3 vezes nas páginas 50, 53 e 62.

¹ De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023.

- CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature. *Geoscientific model development*, Copernicus GmbH, v. 7, n. 3, p. 1247–1250, 2014. Citado na página 64.
- CHANDEL, H.; VATTA, S. Occlusion detection and handling: a review. *International Journal of Computer Applications*, Foundation of Computer Science, v. 120, n. 10, 2015. Citado na página 60.
- CHANG, C.-C.; LIN, C.-J. Libsvm: a library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, Acn, v. 2, n. 3, p. 27, 2011. Citado na página 125.
- CHEDDAD, A. et al. A skin tone detection algorithm for an adaptive approach to steganography. *Signal Processing*, Elsevier, v. 89, n. 12, p. 2465–2478, 2009. Citado 3 vezes nas páginas 58, 59 e 74.
- CHEN, S. S.; DONOHO, D. L.; SAUNDERS, M. A. Atomic decomposition by basis pursuit. *SIAM review*, SIAM, v. 43, n. 1, p. 129–159, 2001. Citado na página 94.
- CHENG, D.; LIU, G.; QIU, Y. Applications of particle swarm optimization and k-nearest neighbors to emotion recognition from physiological signals. In: *2008 International Conference on Computational Intelligence and Security*. [S.l.: s.n.], 2008. v. 2, p. 52–56. Citado na página 102.
- CHIANG, C.-C.; CHEN, Z.-W. Recognizing partially-occluded faces by recovering normalized facial appearance. *International Journal of Innovative Computing, Information and Control*, v. 7, n. 11, p. 6219–6234, 2011. Citado 3 vezes nas páginas 71, 73 e 213.
- CHOLLET, G. et al. Some experiments in audio-visual speech processing. In: SPRINGER. *International Conference on Nonlinear Speech Processing*. [S.l.], 2007. p. 28–56. Citado na página 78.
- COLLIER, D. The comparative method. 1993. Citado 2 vezes nas páginas 107 e 190.
- COLOMBO, A.; CUSANO, C.; SCHETTINI, R. Gappy pca classification for occlusion tolerant 3d face detection. *Journal of mathematical imaging and vision*, Springer, v. 35, n. 3, p. 193–207, 2009. Citado na página 82.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado na página 104.
- COSTA, D. M. M. d. *Ensemble baseado em métodos de Kernel para reconhecimento biométrico multimodal*. Tese (Doutorado) — Universidade de São Paulo, 2011. Citado 4 vezes nas páginas 44, 48, 66 e 100.
- DELAC, K.; GRGIC, M. A survey of biometric recognition methods. In: IEEE. *Electronics in Marine, 2004. Proceedings Elmar 2004. 46th International Symposium*. [S.l.], 2004. p. 184–193. Citado na página 45.
- DENG, Y.; DAI, Q.; ZHANG, Z. Graph laplace for occluded face completion and recognition. *IEEE Transactions on Image Processing*, IEEE, v. 20, n. 8, p. 2329–2338, 2011. Citado 6 vezes nas páginas 72, 92, 95, 111, 113 e 213.

- DOU, P. et al. Pose-robust face signature for multi-view face recognition. In: IEEE. *Biometrics Theory, Applications and Systems (BTAS), 2015 IEEE 7th International Conference on*. [S.l.], 2015. p. 1–8. Citado na página 213.
- DU, S.; SHEHATA, M.; BADAWEY, W. Hard hat detection in video sequences based on face features, motion and color information. In: IEEE. *Computer Research and Development (ICCRD), 2011 3rd International Conference on*. [S.l.], 2011. v. 4, p. 25–29. Citado na página 36.
- DURU, B. M.; TARGINO, J. M.; LIMA, C. A. M. Methods of detecting and reconstructing partial occlusions in face images: Systematic literature review. In: *Workshop de Visão Computacional*. [S.l.: s.n.], 2018. p. 76–81. Citado 2 vezes nas páginas 48 e 194.
- EKENEL, H.; STIEFELHAGEN, R. Why is facial occlusion a challenging problem? *Advances in Biometrics*, Springer, p. 299–308, 2009. Citado na página 61.
- EUM, S.; SUHR, J. K.; KIM, J. Face recognizability evaluation for atm applications with exceptional occlusion handling. In: IEEE. *Computer Vision and Pattern Recognition Workshops (CVPRW), 2011 IEEE Computer Society Conference on*. [S.l.], 2011. p. 82–89. Citado na página 213.
- FENG, G. et al. Error minimized extreme learning machine with growth of hidden nodes and incremental learning. *IEEE Transactions on Neural Networks*, v. 20, n. 8, p. 1352–1357, Aug 2009. ISSN 1045-9227. Citado na página 102.
- FIDLER, S.; SKOCAJ, D.; LEONARDIS, A. Combining reconstructive and discriminative subspace methods for robust classification and regression by subsampling. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 28, n. 3, p. 337–350, March 2006. ISSN 0162-8828. Citado na página 73.
- FILIPE, S. B. *Segmentação de faces em imagens no infravermelho térmico*. Tese (Doutorado), 2010. Citado na página 34.
- FINIZOLA, J. S. et al. A comparative study between deep learning and traditional machine learning techniques for facial biometric recognition. In: *Iberamia*. [S.l.: s.n.], 2018. p. 1–12. Citado 3 vezes nas páginas 34, 125 e 195.
- FINIZOLA, J. S. et al. Comparative study between deep face, autoencoder and traditional machine learning techniques aiming at biometric facial recognition. In: *International Joint Conference on Neural Networks (IJCNN)*. [S.l.: s.n.], 2019. p. 1–8. Citado na página 195.
- FREUND, Y.; SCHAPIRE, R.; ABE, N. A short introduction to boosting. *Journal-Japanese Society For Artificial Intelligence*, JAPANESE SOC ARTIFICIAL INTELL, v. 14, n. 771-780, p. 1612, 1999. Citado na página 57.
- GALDI, C.; NAPPI, M.; DUGELAY, J.-L. Multimodal authentication on smartphones: Combining iris and sensor recognition for a double check of user identity. *Pattern Recognition Letters*, Elsevier, v. 82, p. 144–153, 2016. Citado 2 vezes nas páginas 48 e 125.
- GEORGE, A. S. et al. An efficient gait recognition system for human identification using neural networks. 2017. Citado na página 48.

- GEORGHIADES, A.; BELHUMEUR, P.; KRIEGMAN, D. Yale face database. *Center for computational Vision and Control at Yale University*, <http://cvc.yale.edu/projects/yalefaces/yalefa>, v. 2, 1997. Citado 4 vezes nas páginas 101, 116, 117 e 119.
- GHIASI, G.; FOWLKES, C. C. Occlusion coherence: Localizing occluded faces with a hierarchical deformable part model. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 2385–2392. Citado na página 36.
- HAN, E.-H. S.; KARYPIS, G.; KUMAR, V. Text categorization using weight adjusted k-nearest neighbor classification. In: _____. *Advances in Knowledge Discovery and Data Mining: 5th Pacific-Asia Conference, PAKDD 2001 Hong Kong, China, April 16–18, 2001 Proceedings*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2001. p. 53–65. ISBN 978-3-540-45357-4. Disponível em: <http://dx.doi.org/10.1007/3-540-45357-1_9>. Citado na página 102.
- HASSABALLAH, M.; ALY, S. Face recognition: challenges, achievements and future directions. *IET Computer Vision*, IET, v. 9, n. 4, p. 614–626, 2015. Citado na página 34.
- HOSOI, T. et al. Restoring occluded regions using fw-pca for face recognition. In: IEEE. *Computer Vision and Pattern Recognition Workshops (CVPRW), 2012 IEEE Computer Society Conference on*. [S.l.], 2012. p. 23–30. Citado 3 vezes nas páginas 72, 88 e 213.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. *Neurocomputing*, v. 70, n. 1–3, p. 489 – 501, 2006. ISSN 0925-2312. Neural Networks Selected Papers from the 7th Brazilian Symposium on Neural Networks (SBRN '04) 7th Brazilian Symposium on Neural Networks. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231206000385>>. Citado 2 vezes nas páginas 102 e 103.
- HUANG, J.-B.; YANG, M.-H. Fast sparse representation with prototypes. In: IEEE. *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*. [S.l.], 2010. p. 3618–3625. Citado 3 vezes nas páginas 94, 108 e 110.
- HUANG, S.-M.; YANG, J.-F. Subface hidden markov models coupled with a universal occlusion model for partially occluded face recognition. *IET biometrics*, IET, v. 1, n. 3, p. 149–159, 2012. Citado 2 vezes nas páginas 71 e 213.
- HWANG, B.-W. et al. Face reconstruction from a small number of feature points. In: IEEE. *Pattern Recognition, 2000. Proceedings. 15th International Conference on*. [S.l.], 2000. v. 2, p. 838–841. Citado na página 73.
- JAFRI, R.; ARABNIA, H. R. A survey of face recognition techniques. *Jips*, v. 5, n. 2, p. 41–68, 2009. Citado na página 34.
- JAIN, A. K.; ROSS, A.; PRABHAKAR, S. An introduction to biometric recognition. *IEEE Transactions on circuits and systems for video technology*, IEEE, v. 14, n. 1, p. 4–20, 2004. Citado 2 vezes nas páginas 44 e 45.
- JIA, H.; MARTINEZ, A. M. Support vector machines in face recognition with occlusions. In: *IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2009. p. 136–141. ISSN 1063-6919. Citado na página 73.

JOLLIFFE, I. *Principal component analysis*. [S.l.]: Wiley Online Library, 2002. Citado na página 83.

KACUR, J.; VARGIC, R.; MULINKA, P. Speaker identification by k-nearest neighbors: Application of pca and lda prior to knn. In: *2011 18th International Conference on Systems, Signals and Image Processing*. [S.l.: s.n.], 2011. p. 1–4. ISSN 2157-8672. Citado na página 102.

KIM, J. et al. Effective representation using ica for face recognition robust to local distortion and partial occlusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 27, n. 12, p. 1977–1981, Dec 2005. ISSN 0162-8828. Citado na página 71.

KUMAR, S. S.; KATHIRESAN, V. Gait biometric recognition using direct classification, tsvm, svm and neural network. *Asian Journal of Science and Applied Technology*, v. 6, n. 1, p. 28–31, 2017. Citado na página 48.

LAI, J.; JIANG, X. Robust face recognition using trimmed linear regression. In: *ICASSP*. [S.l.: s.n.], 2013. p. 2979–2983. Citado 2 vezes nas páginas 70 e 213.

LI, X.-X. et al. Structured sparse error coding for face recognition with occlusion. *IEEE transactions on image processing*, IEEE, v. 22, n. 5, p. 1889–1900, 2013. Citado na página 213.

LITCHFIELD, J. a.; WILCOXON, F. A simplified method of evaluating dose-effect experiments. *Journal of pharmacology and experimental therapeutics*, ASPET, v. 96, n. 2, p. 99–113, 1949. Citado 2 vezes nas páginas 140 e 180.

LONE, M. A.; ZAKARIYA, S.; ALI, R. Automatic face recognition system by combining four individual algorithms. In: IEEE. *Computational Intelligence and Communication Networks (CICN), 2011 International Conference on*. [S.l.], 2011. p. 222–226. Citado 2 vezes nas páginas 45 e 50.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vision*, Kluwer Academic Publishers, Hingham, MA, USA, v. 60, n. 2, p. 91–110, nov. 2004. ISSN 0920-5691. Disponível em: <<https://doi.org/10.1023/B:VISI.0000029664.99615.94>>. Citado na página 51.

LUMINI, A.; NANNI, L. Overview of the combination of biometric matchers. *Inf. Fusion*, Elsevier, v. 33, p. 71–85, 2017. Citado 3 vezes nas páginas 34, 35 e 50.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, Ieee, v. 11, n. 7, p. 674–693, 1989. Citado na página 99.

MARSICO, M. D.; NAPPI, M.; RICCIO, D. Faro: Face recognition against occlusions and expression variations. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, IEEE, v. 40, n. 1, p. 121–132, 2010. Citado na página 213.

MARTINEZ, A. M. The ar face database. *CVC technical report*, v. 24, 1998. Citado 10 vezes nas páginas 46, 47, 54, 58, 61, 77, 79, 116, 117 e 118.

MARTINEZ, A. M. Recognizing imprecisely localized, partially occluded, and expression variant faces from a single sample per class. *IEEE Trans. on Pat. Analysis and Machine Intelligence*, v. 24, n. 6, p. 748–763, Jun 2002. ISSN 0162-8828. Citado na página 71.

MIN, R.; DUGELAY, J.-L. Inpainting of sparse occlusion in face recognition. In: IEEE. *Image Processing (ICIP), 2012 19th IEEE International Conference on*. [S.l.], 2012. p. 1425–1428. Citado na página 213.

MIN, R.; HADID, A.; DUGELAY, J.-L. Improving the recognition of faces occluded by facial accessories. In: IEEE. *Automatic Face & Gesture Recognition and Workshops (FG 2011), 2011 IEEE International Conference on*. [S.l.], 2011. p. 442–447. Citado na página 73.

MIN, R.; HADID, A.; DUGELAY, J.-L. Efficient detection of occlusion prior to robust face recognition. *The Scientific World Journal*, Hindawi, v. 2014, 2014. Citado 3 vezes nas páginas 35, 36 e 54.

NASUTION, A. L.; BAYU, D. B. S.; MIURA, J. Person identification by face recognition on portable device for teaching-aid system: Preliminary report. In: IEEE. *Advanced Informatics: Concept, Theory and Application (ICAICTA), 2014 International Conference of*. [S.l.], 2014. p. 171–176. Citado na página 188.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, p. 971–987, July 2002. ISSN 0162-8828. Citado na página 51.

OLOYEDE, M. O.; HANCKE, G. P.; KAPILESWAR, N. Evaluating the effect of occlusion in face recognition systems. In: IEEE. *AFRICON, 2017 IEEE*. [S.l.], 2017. p. 1547–1551. Citado 3 vezes nas páginas 35, 36 e 60.

PARK, J.-S. et al. Glasses removal from facial image using recursive error compensation. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 27, n. 5, p. 805–811, 2005. Citado 2 vezes nas páginas 60 e 84.

PASSALIS, G. et al. Using facial symmetry to handle pose variations in real-world 3d face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 33, n. 10, p. 1938–1951, 2011. Citado na página 213.

PENEV, P. S.; ATICK, J. J. Local feature analysis: a general statistical theory for object representation. *Network: Comp. in Neural Sys.*, p. 477–500, 1996. Citado 2 vezes nas páginas 51 e 71.

PRABHAKAR, S.; PANKANTI, S.; JAIN, A. K. Biometric recognition: Security and privacy concerns. *IEEE security & privacy*, IEEE, v. 99, n. 2, p. 33–42, 2003. Citado na página 66.

RAGASHE, M. U.; GOSWAMI, M.; RAGHUWANSHI, M. Approach towards real time face recognition in streaming video under partial occlusion. In: IEEE. *Intelligent Systems and Control (ISCO), 2015 IEEE 9th International Conference on*. [S.l.], 2015. p. 1–7. Citado na página 60.

SAJJAD, M. et al. Cnn-based anti-spoofing two-tier multi-factor authentication system. *Pattern Recognition Letters*, Elsevier, 2018. Citado na página 34.

SARKAR, M.; LEONG, T. T. Application of k-nearest neighbors algorithm on breast cancer diagnosis problem. In: *Proceedings of the AMIA Annual Symposium, Los Angeles, USA*. [S.l.: s.n.], 2000. Citado na página 102.

SCHOLKOPF, B.; SMOLA, A. J. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. Cambridge, MA, USA: MIT Press, 2001. ISBN 0262194759. Citado na página 104.

SHARIF, M.; MOHSIN, S.; JAVED, M. Y. A survey: Face recognition techniques. *Research Journal of Applied Sciences, Engineering and Technology*, Maxwell Science Publishing, v. 4, n. 23, p. 4979–4990, 2012. Citado 2 vezes nas páginas 44 e 45.

SHARMA, M.; PRAKASH, S.; GUPTA, P. An efficient partial occluded face recognition system. *Neurocomputing*, Elsevier, v. 116, p. 231–241, 2013. Citado 4 vezes nas páginas 70, 73, 74 e 213.

SHERMINA, J.; VASUDEVAN, V. Recognition of the face images with occlusion and expression. *International Journal of Pattern Recognition and Artificial Intelligence*, World Scientific, v. 26, n. 03, p. 1256006, 2012. Citado 6 vezes nas páginas 35, 45, 71, 73, 75 e 213.

SÖDERSTRÖM, U.; LI, H. *Asymmetrical principal component analysis theory and its applications to facial video coding*. [S.l.]: INTECH Open Access Publisher, 2011. Citado na página 83.

SONG, M. et al. Three-dimensional face reconstruction from a single image by a coupled rbf network. *IEEE Transactions on Image Processing*, IEEE, v. 21, n. 5, p. 2887–2897, 2012. Citado na página 213.

SRINIVASAN, A.; BALAMURUGAN, V. Occlusion detection and image restoration in 3d face image. In: IEEE. *TENCON 2014-2014 IEEE Region 10 Conference*. [S.l.], 2014. p. 1–6. Citado na página 60.

STORER, M. et al. Fast-robust pca. In: SPRINGER. *Scandinavian Conference on Image Analysis*. [S.l.], 2009. p. 430–439. Citado 3 vezes nas páginas 73, 87 e 88.

STORER, M.; URSCHLER, M.; BISCHOF, H. Occlusion detection for icao compliant facial photographs. In: IEEE. *Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on*. [S.l.], 2010. p. 122–129. Citado na página 213.

SU, Y.; AI, H.; LAO, S. Multi-view face alignment using 3d shape model for view estimation. In: SPRINGER. *International Conference on Biometrics*. [S.l.], 2009. p. 179–188. Citado 2 vezes nas páginas 72 e 213.

TAIGMAN, Y. et al. Deepface: Closing the gap to human-level performance in face verification. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 1701–1708. ISSN 1063-6919. Citado na página 51.

TAJIMA, Y. et al. Performance improvement of face recognition algorithms using occluded-region detection. In: IEEE. *Biometrics (ICB), 2013 International Conference on*. [S.l.], 2013. p. 1–8. Citado 2 vezes nas páginas 36 e 62.

TAN, X. et al. Recognizing partially occluded, expression variant faces from single training image per person with som and soft k-nn ensemble. *IEEE Transactions on Neural Networks*, v. 16, n. 4, p. 875–886, July 2005. ISSN 1045-9227. Citado na página 71.

TAN, X. et al. Recognizing partially occluded, expression variant faces from single training image per person with som and soft k-nn ensemble. *IEEE Transactions on Neural Networks*, IEEE, v. 16, n. 4, p. 875–886, 2005. Citado 2 vezes nas páginas 71 e 213.

TAN, X. et al. Face recognition under occlusions and variant expressions with partial similarity. *IEEE Transactions on Information Forensics and Security*, IEEE, v. 4, n. 2, p. 217–230, 2009. Citado na página 60.

TARGINO, J. M.; PERES, S. M.; LIMA, C. A. M. Detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico. In: *X Workshop de Teses e Dissertações de Sistemas de Informação*. [S.l.: s.n.], 2017. p. 64–67. Citado na página 194.

TARGINO, J. M.; PERES, S. M.; LIMA, C. A. M. Estudo comparativo de técnicas baseadas em subespaço na tarefa de reconstrução de faces parcialmente ocluídas. In: *Simpósio Brasileiro de Sistemas de Informação*. [S.l.: s.n.], 2018. p. 1–4. Citado na página 195.

TARGINO, J. M.; PERES, S. M.; LIMA, C. A. M. Methods of detecting and reconstructing partial occlusions in face images: Systematic literature review. In: *Workshop de Visão Computacional*. [S.l.: s.n.], 2018. p. 76–81. Citado 4 vezes nas páginas 39, 70, 194 e 211.

TARGINO, J. M.; PERES, S. M.; LIMA, C. A. M. Técnicas baseadas em subespaço para reconstrução de faces parcialmente ocluídas: Um estudo comparativo. In: *Computer on the Beach*. [S.l.: s.n.], 2018. p. 228–237. Citado na página 195.

TARGINO, J. M.; PERES, S. M.; LIMA, C. A. M. Técnicas de detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico. In: *XI Workshop de Teses e Dissertações de Sistemas de Informação*. [S.l.: s.n.], 2018. p. 1–10. Citado na página 195.

THUNG, K.-H.; RAVEENDRAN, P. A survey of image quality measures. In: IEEE. *Technical Postgraduates (TECHPOS), 2009 International Conference for*. [S.l.], 2009. p. 1–4. Citado 2 vezes nas páginas 64 e 114.

TURK, M. A.; PENTLAND, A. P. Face recognition using eigenfaces. In: IEEE. *Computer Vision and Pattern Recognition, 1991. Proceedings CVPR'91., IEEE Computer Society Conference on*. [S.l.], 1991. p. 586–591. Citado 3 vezes nas páginas 50, 78 e 80.

VAPNIK, V. N. *The nature of statistical learning theory*. New York, NY, USA: Springer-Verlag New York, Inc., 1995. ISBN 0-387-94559-8. Citado na página 104.

VENKATAKRISHNAN, D. et al. 3d face recognition with occlusions using fisher faces projection. *Applied Mechanics & Materials*, n. 573, 2014. Citado na página 60.

- VIOLA, P.; JONES, M. J. Robust real-time face detection. *International journal of computer vision*, Springer, v. 57, n. 2, p. 137–154, 2004. Citado 2 vezes nas páginas 55 e 118.
- WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, IEEE, v. 13, n. 4, p. 600–612, 2004. Citado 3 vezes nas páginas 63, 109 e 114.
- WANG, Z.-M.; TAO, J.-H. Reconstruction of partially occluded face by fast recursive pca. In: IEEE. *Computational Intelligence and Security Workshops, 2007. CISW 2007. International Conference on*. [S.l.], 2007. p. 304–307. Citado 2 vezes nas páginas 86 e 109.
- WEI, X.; LI, C.-T.; HU, Y. Robust face recognition with occlusions in both reference and query images. In: IEEE. *Biometrics and Forensics (IWBF), 2013 International Workshop on*. [S.l.], 2013. p. 1–4. Citado na página 213.
- WEI, X. et al. Dynamic image-to-class warping for occluded face recognition. *IEEE Transactions on Information Forensics and Security*, IEEE, v. 9, n. 12, p. 2035–2050, 2014. Citado 4 vezes nas páginas 36, 60, 70 e 213.
- WISKOTT, L. et al. Face recognition by elastic bunch graph matching. In: *Proceedings of International Conference on Image Processing*. [S.l.: s.n.], 1997. v. 1, p. 129–132 vol.1. Citado na página 51.
- WRIGHT, J. et al. Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 31, n. 2, p. 210–227, Feb 2009. ISSN 0162-8828. Citado na página 51.
- WRIGHT, J. et al. Robust face recognition via sparse representation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, v. 31, n. 2, p. 210–227, Feb 2009. ISSN 0162-8828. Citado na página 93.
- WRIGHT, J. et al. Robust face recognition via sparse representation. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 31, n. 2, p. 210–227, 2009. Citado 4 vezes nas páginas 93, 109, 113 e 213.
- XIE, W.; ZISSERMAN, A. Multicolumn networks for face recognition. *arXiv preprint arXiv:1807.09192*, 2018. Citado na página 50.
- YAN, S. et al. Misalignment-robust face recognition. *IEEE trans. on image processing*, IEEE, v. 19, n. 4, p. 1087–1096, 2010. Citado na página 213.
- YANG, M. et al. Fast and robust face recognition via coding residual map learning based adaptive masking. *Pattern Recognition*, Elsevier, v. 47, n. 2, p. 535–543, 2014. Citado 2 vezes nas páginas 113 e 213.
- YANG, M. et al. Metaface learning for sparse representation based face recognition. In: IEEE. *Image Processing (ICIP), 2010 17th IEEE International Conference on*. [S.l.], 2010. p. 1601–1604. Citado na página 93.
- YI, J.; YANG, H.; KIM, Y. Enhanced fisherfaces for robust face recognition. In: SPRINGER. *International Workshop on Biologically Motivated Computer Vision*. [S.l.], 2000. p. 502–511. Citado na página 188.

YU, X. P.; YU, X. G. Novel text classification based on k-nearest neighbor. In: *2007 International Conference on Machine Learning and Cybernetics*. [S.l.: s.n.], 2007. v. 6, p. 3425–3430. ISSN 2160-133X. Citado na página 102.

ZHANG, B.; CERONE, P.; GAO, Y. Robust face recognition by hierarchical kernel associative memory models based on spatial domain gabor transforms. *Journal of Multimedia*, v. 1, n. 4, p. 1–10, 2006. Citado 2 vezes nas páginas 72 e 213.

ZHANG, B. et al. Histogram of gabor phase patterns (hgpp): A novel object representation approach for face recognition. *IEEE Trans. on Image Processing*, v. 16, n. 1, p. 57–68, Jan 2007. ISSN 1057-7149. Citado na página 71.

ZHANG, L. et al. On the dimensionality reduction for sparse representation based face recognition. In: IEEE. *Pattern Recognition (ICPR), 2010 20th International Conference on*. [S.l.], 2010. p. 1237–1240. Citado na página 93.

ZHANG, T. et al. Fast and robust occluded face detection in atm surveillance. *Pattern Recognition Letters*, Elsevier, v. 107, p. 33–40, 2018. Citado na página 54.

ZHANG, Y. et al. Face occlusion detection using cascaded convolutional neural network. In: SPRINGER. *Chinese Conference on Biometric Recognition*. [S.l.], 2016. p. 720–727. Citado 3 vezes nas páginas 37, 70 e 213.

ZHU, J. et al. Discriminant analysis with gabor phase for robust face recognition. In: IEEE. *Biometrics (ICB), 2012 5th IAPR International Conference on*. [S.l.], 2012. p. 13–18. Citado na página 213.

ZUO, W.; WANG, K.; ZHANG, H. Subspace methods for face recognition: Singularity, regularization, and robustness. In: *State of the Art in Face Recognition*. [S.l.]: InTech, 2009. Citado na página 183.

Apêndice A – Protocolo de revisão sistemática sobre técnicas para detecção e reconstrução de oclusões parciais em imagens de face

A.1 *Objetivo*

O objetivo principal dessa revisão sistemática foi realizar um levantamento sistemático do estado de arte, referente a técnicas de detecção e reconstrução de oclusões parciais em imagens de faces humanas visando o reconhecimento biométrico. Mediante esse estudo, foi possível extrair dados para o tema desta dissertação, a fim de conseguir informações pertinentes, como por exemplo: quais algoritmos estão sendo aplicados para detectar oclusões parciais, e reconstruir faces parcialmente ocluídas, quais as métricas de avaliação que são normalmente utilizadas, quais estratégias estão apresentando melhor resultado, quais as condições do ambiente, e quais bases de dados utilizadas.

A.2 *Questões de pesquisa*

Em adição aos objetivos da revisão sistemática elaborada, as questões de pesquisa auxiliam na busca por informações relevantes por meio da leitura integral dos estudos. Tais informações são obtidas após a extração e síntese dos dados extraídos da leitura. As questões de pesquisa levantadas foram:

1. quais técnicas estão sendo utilizadas para reconstrução de faces humanas e como são aplicadas?
2. quais as técnicas utilizadas para detecção de oclusões parciais e como são aplicadas?
3. como os resultados são analisados e comparados?
4. qual tipo de reconhecimento biométrico foi utilizado?
5. Quais bases de dados estão sendo utilizadas?

A.3 *Seleção de fontes*

Para selecionar os estudos primários para essa revisão sistemática, foram utilizadas as três bases indexadoras a seguir:

Os trabalhos devem estar preferencialmente disponíveis na internet, em bases de dados científicas. As seguintes bases foram selecionadas para realização das buscas:

1. Biblioteca Digital do Scopus (<https://www.scopus.com/>)
2. Biblioteca Digital do IEEE (<http://ieeexplore.ieee.org/Xplore/home.jsp>)
3. Biblioteca Digital do Web of Science (<https://apps.webofknowledge.com>)

A justificativa para a escolha dessas três bases se refere à abrangência, quase total, dos artigos presentes nas bibliotecas digitais com idioma na língua inglesa. Para encontrar tais artigos nas bases indexadoras, foi elaborado uma string de busca para cada uma das bases com os termos descritos mais detalhadamente na seção A.4. O apêndice B, apresenta com maiores o processo de seleção de artigos.

A.4 *Palavras-Chave*

A *String de busca* envolveu as palavras-chave descritas abaixo:

1. 'occlusion' OR 'occluded';
2. 'detect*' OR 'recogni*' OR 'analys*' OR 'reconstruct*';
3. 'face' OR 'faces' OR 'facial' ;
4. 'biometry*'.

Os artigos retornados pela aplicação da *String* de busca nos motores de busca, foram lidos seus respectivos títulos e resumos.

A.5 *Critérios de inclusão*

Para essa revisão sistemática, três critérios de inclusão foram definidos, sendo eles:

I1 - Artigos que abordem métodos e técnicas utilizadas para detecção de oclusão parciais em faces humanas.

I2 - Artigos que abordem técnicas utilizadas para reconstrução de faces humanas.

I3 - Artigos que abordem modelagens híbridas para detecção de oclusões parciais e/ou reconstrução facial.

A.6 *Critérios de exclusão*

E1 - Artigos de revisão serão excluídos.

E2 - Trabalhos que estejam na forma de livros, capítulos de livros, prefácio de eventos, pôster e artigos resumidos.

E3 - Trabalhos que não estejam na língua Inglesa.

E4 - Trabalhos que não sejam revisados por pares.

A.7 Estratégia de seleção dos dados

Foi construída uma *String* com palavras-chave e seus sinônimos, onde essa *String* foi submetida nas máquinas de busca. Após a leitura dos resumos e títulos e sua posterior aplicação dos critérios de inclusão e exclusão, com isso os artigos foram selecionados conforme sua adequação junto aos critérios de inclusão, apresentando relevância daquele artigo perante a pesquisa.

A.8 Síntese dos dados extraídos

Após a leitura na íntegra de cada artigo incluído, foi elaborado um formulário de extração dos dados, a fim de serem sintetizados e gerar informações pertinentes, os dados coletados foram:

1. autores;
2. objetivo do trabalho;
3. estratégia para detecção de oclusão parcial;
4. estratégia para reconstrução de face;
5. base de dados utilizada;
6. forma de avaliação;
7. métricas utilizadas;
8. identificação das vantagens e desvantagens de cada método;
9. resultados obtidos;
10. limitações do trabalho;
11. trabalhos futuros.

A.9 Ameaças a validade

Os resultados da pesquisa podem revelar que as técnicas ou fusões de técnicas apresentadas para detecção de oclusão ou reconstrução de faces não produzem um bom resultado ou não são aplicáveis a tal ambiente de coleta, assim refutando a hipótese de pesquisa. Outra possível ameaça que este projeto pode apresentar é a existência de outras técnicas com fins a identificar a parte ocluída em uma imagem facial e/ou reconstruir a face sem finalidades biométricas.

A.10 Critérios de qualidade

Após a seleção dos estudos e a leitura integral de cada um deles, existe a necessidade de realizar uma avaliação subjetiva direcionada ao objetivo da revisão sistemática. Desse modo, alguns critérios de qualidade foram desenvolvidos para tal fim, sendo eles:

- Q1 - Os objetivos da pesquisa são claramente definidos?
- Q2 - O contexto é adequadamente descrito?
- Q3 - Foram apresentadas técnicas de detecção de oclusões claramente?
- Q4 - Foram apresentadas técnicas de reconstrução facial?
- Q5 - O código de detecção de oclusões foi disponibilizado?
- Q6 - O código de detecção de reconstrução facial foi disponibilizado?
- Q7 - O ambiente do estudo primário foi apresentado claramente?
- Q8 - A proposta do estudo foi validada?
- Q9 - A proposta é comparada com outro método?
- Q10 - Foi apresentado o *Dataset* utilizado?
- Q11 - O experimento é aplicado em conjuntos de dados suficientes?
- Q12 - Os resultados foram apresentados claramente?

Para cada critério de qualidade necessariamente era atribuído uma nota, sendo Sim (S) = 1 ponto, Não (N) = 0 ponto, e Parcialmente (P) = 0,5.

Apêndice B – Condução da revisão

Após o planejamento da revisão sistemática e definição do protocolo, a condução dos passos consistiram das seguintes etapas: submissão das *strings* nas máquinas de busca do Scopus, IEEE e Web of Science; aplicação dos artigos retornados nas máquinas de busca e aplicação dos critérios de inclusão e exclusão; e extração dos dados dos artigos incluídos e lidos integralmente.

O processo de busca dos artigos foi realizado no período compreendido entre 25 de janeiro e 06 de fevereiro de 2017. A partir dessas buscas 440 artigos foram retornados, de modo que após a aplicação dos critérios de inclusão e exclusão 38 artigos foram selecionados para leitura e análise completa, sendo que após a leitura completa do trabalho foram selecionados 31 artigos com relevante grau de contribuição para a pesquisa. A figura 115 apresenta um esquema do processo de seleção dos artigos.

Figura 115 – Processo de seleção dos artigos

Fonte: Jonas Mendonça Targino, 2019

Apêndice C – Contextualização da literatura

Este capítulo possui como objetivo principal apresentar um apanhado geral das técnicas para detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico. Essas técnicas foram obtidas graças ao trabalho de Targino, Peres e Lima (2018b) o qual apresentou uma revisão sistemática das técnicas presentes na literatura.

C.1 Escopo dos estudos

Dentro do conjunto de estudos selecionados e analisados, existem autores que abordam a técnica de detecção de oclusão e paralelamente realizam a reconstrução da face, entretanto em outros trabalhos são implementados apenas uma das duas técnicas. Diante dos trabalhos lidos foi possível perceber que a maioria deles não apresentaram o algoritmo de construção da técnica de forma detalhada. Sendo possível a implementação da técnica mediante a leitura de outros trabalhos com abordagens semelhantes e mais específicas, abrangendo com isso uma maior quantidade de detalhes. É notável perceber que a maioria dos trabalhos abordaram adaptações de técnicas já existentes para detecção e reconstrução de oclusões parciais.

C.2 Bases de dados

Três bases de dados foram amplamente utilizadas nos trabalhos analisados e esta seção as descreve resumidamente. Em alguns artigos mais de uma base foram utilizadas de modo a possibilitar o uso de uma ou mais bases para o conjunto de treinamento e outra de modo a prover instâncias para o conjunto de teste. Todas as bases de dados utilizadas nos trabalhos abordados na revisão sistemática estão representadas na figura 116, dentre essas apresentadas, aqui será dado maior ênfase nas três bases de dados mais utilizadas, sendo elas:

- **AR** esta base de dados foi utilizada em nove dos trabalhos analisados (29%). Ela possui um pouco mais de 2.600 imagens de face frontal de 100 indivíduos (50 homens e 50 mulheres). De modo que para cada indivíduo são coletadas 26 fotos, estas

coletadas sobre duas sessões (dois dias diferentes) separadas e sujeitas a 13 variações de condições, dentre estas estão, diferentes expressões faciais, condições de iluminação e variações de oclusão (com óculos de sol e cachecol). A base de dados encontra-se disponível em <http://www2.ece.ohio-state.edu/~aleix/ARdatabase.html>;

- **YALE B** esta base de dados contém 165 imagens frontais de 10 pessoas, contendo variações de iluminação, expressão e oclusão (baixos níveis de oclusão). A base de dados foi utilizada em quatro dos trabalhos selecionados (14%), e ela encontra-se disponível em <http://www.face-rec.org/databases/>;
- **FRGC** foi a terceira base de dados mais utilizada, três dos trabalhos analisados (11%) a utilizaram. Esta base de dados contém 12776 imagens frontais de 222 indivíduos, com 6388 imagens coletadas em ambientes controlados e outras 6388 imagens coletadas na presença de ambientes não controlados. Esta base de dados está disponível em <https://www.nist.gov/programs-projects/face-recognition-grand-challenge-frgc>.

Figura 116 – Bases de dados utilizadas pelos estudos selecionados

Fonte: Jonas Mendonça Targino, 2019

Pode-se perceber uma quantidade significativa de bases de dados de face dispostas na literatura, entretanto nem todas as bases disponíveis apresentam uma grande quantidade de imagens bem como também uma grande quantidade de variações existentes. Na tabela 23 são apresentadas algumas das bases mais utilizadas como também número de indivíduos da base, quantidade de imagens, e variações presentes na base. As variações estão apresentadas da forma: **(i)** representa iluminação; **e** significa expressão; **(o)** representa oclusão; e **t** significa variação temporal (ou seja, imagens obtidas da mesma pessoa em diferentes dias).

Tabela 23 – Bases de dados de domínio público e algumas especificações

Bases	Número de indivíduos	Número de imagens	Variações existentes
AR	100	2600	i, e,o, t
Yale B	15	165	i,e
FRGC	222	12776	i,e
ORL	40	400	p,e
MIT	16	432	i,p
CMU PIE	68	41.368	p,i,e
FERET	> 1000	> 10000	p,i,e,t
UMIST	20	564	p

Fonte: Jonas Mendonça Targino, 2019

C.3 Técnicas encontradas na literatura

Após a extração dos dados foi possível analisar as técnicas presentes na literatura para detecção e reconstrução de oclusões parciais com fins biométricos, estas técnicas estão sendo apresentadas com mais detalhes nas subseções C.3.1 e C.3.2 logo abaixo.

De modo a gerar uma melhor visualização dos trabalhos selecionados e uma identificação para cada um deles foi elaborada o quadro 3, este apresentando a identificação do trabalho, como também o evento em que o mesmo foi publicado.

Quadro 3 – Estudos selecionados

ID	Autores	Evento
A1	(BELLIL; BRAHIM; AMAR, 2016)	Multimed Tools Applications
A2	(ZHANG et al., 2016)	Chinese Conference on Biometric Recognition
A3	(DOU et al., 2015)	Biometrics Theory, Applications and Systems (BTAS)
A4	(WEI et al., 2014)	IEEE Transactions on Information Forensics and Security
A5	(AISHA et al., 2014)	KSII Transactions on Internet and Information Systems (THIS)
A6	(YANG et al., 2014)	Pattern Recognition
A7	(ALYUZ; GOKBERK; AKARUN, 2014)	International Conference Pattern Recognition (ICPR)
A8	(BINDU; KUMAR, 2014)	Signal and Image Processing (ICSIP)
A9	(LAI; JIANG, 2013)	International Conference Acoustics, Speech, and Signal Processing (ICASSP)
A10	(SHARMA; PRAKASH; GUPTA, 2013)	Neurocomputing
A11	(WEI; LI; HU, 2013)	International Workshop Biometrics and Forensics (IWBF)
A12	(ALYUZ; GOKBERK; AKARUN, 2013)	IEEE Transactions on Information Forensics and Security
A13	(LI et al., 2013)	IEEE transactions on image processing
A14	(MIN; DUGELAY, 2012)	International Conference Image Processing (ICIP)
A15	(ALYÜZ et al., 2012)	International Conference Biometrics (ICB)
A16	(ZHU et al., 2012)	International Conference Biometrics (ICB)
A17	(SONG et al., 2012)	IEEE Transactions on Image Processing
A18	(SHERMINA; VASUDEVAN, 2012)	International Journal of Pattern Recognition and Artificial Intelligence
A19	(CHIANG; CHEN, 2011)	International Journal of Innovative Computing, Information and Control
A20	(EUM; SUHR; KIM, 2011)	Computer Vision and Pattern Recognition Workshops
A21	(PASSALIS et al., 2011)	IEEE Transactions on Pattern Analysis and Machine Intelligence
A22	(DENG; DAI; ZHANG, 2011)	IEEE Transactions on Image Processing
A23	(STORER; URSCHLER; BISCHOF, 2010)	Computer Vision and Pattern Recognition Workshops (CVPRW)
A24	(YAN et al., 2010)	IEEE transactions on image processing
A25	(MARSICO; NAPPI; RICCIO, 2010)	IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans
A26	(SU; AI; LAO, 2009)	International Conference on Biometrics
A27	(WRIGHT et al., 2009c)	IEEE transactions on pattern analysis and machine intelligence
A28	(ZHANG; CERONE; GAO, 2006)	Journal of Multimedia
A29	(HUANG; YANG, 2012)	IET biometrics
A30	(HOSOI et al., 2012)	Computer Vision and Pattern Recognition Workshops (CVPRW)
A31	(TAN et al., 2005b)	IEEE Transactions on Neural Networks

Fonte: Jonas Mendonça Targino, 2019

C.3.1 Técnicas para detecção de oclusões parciais

Algumas técnicas para detecção de oclusões parciais em imagens de face, coletadas a partir da revisão sistemática estão destacadas no quadro 4. Após a análise deste quadro podemos enxergar um número considerável de técnicas com tal finalidade.

Quadro 4 – Técnicas para detecção de oclusão

ID do Artigo	Nome da Técnica
A1	Transformada Wavelet Discreta(DCT)
A2	Rede Neural Convolutacional(CNN)
A4,A11	Imagens Dinâmicas para Classes Deformadas(DICW)
A5	Kernel Incremental de Análise Discriminante de Fisher (IKFDA)
A6,A25,A32	Classificação por Representação Esparsa (SRC)
A14	Máscara de Projeção FisherFace
A7	Mistura de Modelos Gaussianos (GMM)
A9	Classificação de regressão linear aparada (TLRC)
A10	Filtros de Gabor
A13	Estrutura Esparsa de Codificação do Erro(SSEC)
A14	Robusta Análise dos Componentes Principais (RPCA)
A15	ICP junto ao modelo genérico facial
A16	Fases de Gabor com SLRDA
A18	Bloco de Algoritmo de correspondência (BMA)
A19	Descoberta Iterativa de Faces(IFR)
A20	Manipulação de Oclusões Excepcionais(EOH)
A23	Técnica do Espaço de Cores (CST)
A24	Desalinhamento Robusto (MAR)
A25	Reconhecimento Facial contra Oclusão(FARO)
A26	Multi Visões de Alinhamento de Faces
A28	Memória de Kernel Associativo(KAM)
A29	Modelos Ocultos Markovianos (HMM)
A31	Mapa de Auto Organização(SOM)

Fonte: Jonas Mendonça Targino, 2019

C.3.2 Técnicas para reconstrução de imagens de Faces

Após a fase de detecção da oclusão na imagem da face, torna-se imprescindível a reconstrução da oclusão, de modo a possibilitar a identificação biométrica. A partir da leitura dos artigos foi possível extrair algumas técnicas para reconstrução de faces. As técnicas encontradas são apresentadas no quadro 5. Analisando este quadro pode-se

perceber um pequeno número de técnicas com tal finalidade quando comparado com as técnicas para detecção de oclusão.

Quadro 5 – Técnicas para reconstrução de faces

ID do Artigo	Nome da Técnica
A1	Rede Neural de Onda de Multi-Biblioteca (MLWNN)
A4,A27	SRC
A7	Inpainting for big data (IBD)
A9	TLRC
A10	Eigenfaces com Eigenfaces reformados de Gabor(RGEF)
A12,A15	Gappy Análise dos Componentes Principais (GPCA)
A16	Fases de Gabor com RSLDA
A18,A19,A24	Eigenfaces
A22	Grafos Laplacianos
A23	CST + Modelos de Formas Ativas (ASM) e PCA
A28	KAM
A30	Pesos Rápidos de Análises de Componentes Principais (FWPCA)

Fonte: Jonas Mendonça Targino, 2019

C.4 Considerações finais do apêndice

Considerando a importância das técnicas de detecção e reconstrução de oclusões parciais em imagens de face visando o reconhecimento biométrico. Neste apêndice foi apresentada uma revisão sistemática de literatura a respeito das técnicas presentes no estado da arte com fins de detecção e/ou reconstrução de oclusões parciais em imagens de face.

Com a análise dos artigos incluídos percebeu-se que existe uma quantidade considerável de técnicas presentes na literatura, entretanto essas técnicas apresentam configurações de execuções limitadas, não seguindo um rigor sistemático de bases de dados utilizadas, como também disponibilidade de códigos ou pseudocódigos para futuras replicações por outras pessoas interessadas na área.

Foi possível concluir com essa revisão sistemática, que a área apresenta uma certa instabilidade em relação a padrões de execuções, tipos de oclusões, sem contar que alguns autores não utilizam um estudo comparativo mais aprofundado com outras técnicas presentes no estado da arte. Como também grande parte dos artigos não apresentam fins que possibilitem replicação do trabalho pela comunidade científica.

Apêndice D – Matrizes de confusão

Abaixo são apresentadas as matrizes de confusão de cada técnica, de modo que após a análise da diagonal é possível perceber qual classe teve um maior índice de acertos, como também seus falsos positivos e falsos negativos.

D.1 Técnicas baseadas em subespaço

Figura 117 – Matriz de confusão da técnica *Asymmetrical PCA* na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 118 – Matriz de confusão da técnica *Fast Recursive PCA* na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 119 – Matriz de confusão da técnica Fisherfaces na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 120 – Matriz de confusão da técnica *Fast Robust PCA* na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 121 – Matriz de confusão da técnica *Gappy PCA* na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 122 – Matriz de confusão da técnica PCA na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 123 – Matriz de confusão da técnica *Recursive* PCA na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 124 – Matriz de confusão da técnica SRC com *Fast Recursive PCA* na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

D.2 Técnicas baseadas em modelo

Figura 125 – Matriz de confusão da técnica SRC com grafo de Poisson na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 126 – Matriz de confusão da técnica SRC com grafo Laplaciano na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Figura 127 – Matriz de confusão da técnica SSIMGL na base de dados AR

Fonte: Jonas Mendonça Targino, 2019

Apêndice E – Tabelas de resultados

E.1 Resultados de reconstrução com técnicas baseadas em subespaço

E.1.1 Resultados com ELM

Tabela 24 – Taxa de reconhecimento com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	40.99±2.02	39.53±2.98	37.55±1.53	37.68±1.74	40.00±3.34
	500	44.74±2.74	46.85±2.02	42.94±3.24	45.89±1.82	45.05±1.66
	1000	25.10±1.65	28.61±1.74	26.87±1.92	28.20±1.37	26.65±1.61
	2000	25.17±2.10	29.88±2.15	28.56±2.10	29.13±1.59	29.46±1.92
	4000	41.33±1.81	45.90±2.17	44.20±1.32	44.70±1.64	43.38±2.27

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	50.52±2.41	47.00±2.42	46.4±1.37	45.30±2.83	49.12±3.96
	500	53.62±3.58	55.02±2.49	52.12±4.75	55.2±1.67	54.85±3.29
	1000	30.97±2.72	34.32±3.00	32.52±2.34	34.375±1.96	32.22±2.84
	2000	30.22±3.39	34.82±3.23	33.62±3.09	35.075±2.05	35.22±2.28
	4000	46.67±2.65	50.45±2.95	49.75±2.19	50.75±2.02	48.47±2.55

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	39.83±2.30	38.81±4.20	32.08±3.85	34.13±2.99	39.20±5.01
	500	46.10±3.30	51.51±2.68	44.91±3.99	46.76±3.20	48.53±1.90
	1000	31.85±2.46	37.58±3.29	35.80±3.48	38.18±2.63	35.86±2.59
	2000	32.18±4.75	39.75±3.51	39.35±4.27	41.90±2.33	42.31±2.81
	4000	50.63±3.58	57.10±2.89	56.60±1.62	59.70±3.46	58.03±3.26

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	41.25±3.38	39.36±3.42	42.48±2.45	40.65±3.18	39.70±3.81
	500	42.43±4.09	41.38±3.60	40.75±3.85	44.21±1.44	40.15±2.88
	1000	17.66±2.45	18.96±1.71	18.65±2.68	17.93±2.89	16.93±1.52
	2000	17.33±2.09	19.38±1.82	18.00±2.71	16.31±2.44	16.31±1.78
	4000	30.73±2.10	33.16±2.87	31.66±3.27	29.65±2.12	28.63±2.74

Tabela 25 – Taxa de reconhecimento com ELM na base de dados Yale com oclusões com nível de decomposição LL3

		Yale#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	77.33±14.12	70.66±12.64	63.33±13.78	67.33±14.55	68.00±10.32
	500	96.00±4.66	90.66±7.16	79.33±11.52	89.33±7.16	93.33±6.28
	1000	96.66±3.51	94.00±3.78	80.66±4.91	93.33±7.02	96.00±3.44
	2000	98.66±2.81	94.66±2.81	84.00±6.44	98.00±3.22	98.00±3.22
	4000	100.00±0.00	94.66±2.81	83.33±5.66	100.00±0.00	98.00±3.22

		Yale#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	57.33±10.03	47.33±14.21	58.00±14.41	44.00±9.53	52.66±15.53
	500	78.00±7.06	79.33±6.62	75.33±6.32	70.00±6.47	74.00±6.62
	1000	79.33±5.83	83.33±3.51	81.33±2.81	76.66±5.66	80.66±6.62
	2000	80.66±3.78	87.33±5.83	84.00±3.44	79.33±6.62	81.33±4.21
	4000	81.33±4.21	85.33±4.21	86.00±2.10	78.66±6.12	82.66±4.66

Fonte: Jonas Mendonça Targino. 2019

Tabela 26 – Taxa de reconhecimento da técnica *Asymmetrical PCA* com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	35.41±2.20	34.22±2.70	32.02±1.26	32.24±1.92	34.47±3.36
	500	39.11±3.04	41.70±2.05	37.35±3.37	40.87±2.28	39.70±2.38
	1000	21.85±1.55	24.20±1.63	23.04±1.77	25.17±1.00	23.60±1.48
	2000	21.26±2.32	25.16±2.24	25.20±2.00	25.56±1.54	26.25±1.86
	4000	35.68±1.55	40.91±2.17	39.45±1.16	40.45±1.88	39.10±2.02

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	43.57±2.88	41.62±3.26	39.42±1.66	39.10±3.46	42.70±3.82
	500	48.07±3.87	50.80±3.49	46.17±4.71	50.97±2.44	48.50±3.47
	1000	27.32±2.72	29.57±2.22	28.72±2.11	31.55±1.92	29.60±1.78
	2000	25.67±2.97	31.00±3.17	30.07±2.86	31.60±1.78	32.15±2.59
	4000	40.45±2.37	45.97±2.51	45.00±1.81	46.37±2.42	44.10±2.63

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	36.76±2.228	36.38±4.00	29.18±3.43	30.96±2.65	36.03±5.14
	500	43.08±4.2392	49.01±2.02	40.41±4.24	43.36±3.44	45.35±1.97
	1000	29.40±2.1662	34.00±3.55	31.66±2.86	35.76±2.54	33.83±1.92
	2000	29.06±4.576	35.78±2.78	35.73±3.69	38.30±2.57	39.66±3.26
	4000	46.21±3.373	53.36±2.95	53.08±2.05	55.75±3.30	54.45±2.08

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	34.06±2.93	32.06±3.34	34.86±2.99	33.51±3.36	32.91±3.31
	500	35.15±4.16	34.38±3.88	34.28±4.34	38.38±2.20	34.06±4.07
	1000	14.31±2.46	14.40±1.18	14.41±1.25	14.58±2.69	13.36±1.76
	2000	13.46±1.19	14.55±2.54	14.66±2.68	12.83±2.72	12.83±1.35
	4000	25.15±1.78	28.46±2.98	25.83±3.01	25.16±2.46	23.76±2.87

Fonte: Jonas Mendonça Targino. 2019

Tabela 27 – Taxa de reconhecimento da técnica *Fast Recursive PCA* com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	70.80±0.96	69.55±1.19	69.47±1.19	68.26±1.11	68.25±1.32
	500	71.56±1.34	70.95±1.68	71.37±0.78	70.91±1.19	69.18±0.99
	1000	51.15±0.98	50.94±1.70	50.36±1.27	50.65±1.06	48.65±1.42
	2000	54.15±1.14	53.30±1.56	53.61±1.45	50.81±1.07	50.10±1.77
	4000	68.16±0.80	69.06±1.26	69.07±0.93	65.34±1.29	64.90±1.20

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	87.97±0.74	86.00±0.84	86.42±1.37	84.75±0.98	83.50±1.29
	500	85.52±0.74	83.90±1.79	85.72±0.98	83.27±0.75	82.07±0.87
	1000	64.82±1.38	63.87±1.55	63.62±1.74	63.97±1.48	61.57±1.14
	2000	68.22±2.57	66.70±1.53	65.85±1.06	63.37±1.53	62.25±2.33
	4000	79.70±1.34	79.15±1.40	80.10±1.29	76.15±0.93	76.00±0.95

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	78.28±1.15	77.66±1.38	77.38±1.90	76.28±1.76	76.35±1.82
	500	83.46±2.11	82.33±1.05	83.66±1.43	82.35±1.22	81.88±1.35
	1000	66.68±1.47	66.60±1.89	65.91±1.88	67.00±1.79	64.96±1.62
	2000	70.50±2.10	70.28±1.97	70.15±2.25	68.81±1.76	67.46±2.30
	4000	82.40±1.03	83.46±1.32	83.18±0.56	81.06±1.68	80.50±1.49

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	63.33±1.09	61.43±3.13	61.56±1.65	60.25±1.63	60.15±2.12
	500	59.66±1.34	59.56±3.18	59.08±1.36	59.48±1.48	56.48±1.59
	1000	35.61±1.03	35.28±1.72	34.81±1.91	34.31±1.88	32.35±1.73
	2000	37.80±1.77	36.33±1.71	37.08±1.75	32.81±1.46	32.73±2.04
	4000	53.93±1.46	54.66±1.49	54.96±1.56	49.61±1.33	49.31±1.55

Fonte: Jonas Mendonça Targino. 2019

Tabela 28 – Taxa de reconhecimento da técnica Fisherfaces com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	18.46±1.29	18.24±1.02	18.12±0.88	17.56±1.18	18.37±0.95
	500	14.37±0.87	14.69±1.40	15.50±1.10	15.63±0.94	14.61±1.12
	1000	7.23±0.87	7.60±1.02	7.37±0.48	8.40±1.10	7.103±1.06
	2000	6.67±1.46	7.11±0.81	7.25±0.70	7.00±1.03	6.80±0.89
	4000	9.93±1.40	10.70±1.34	11.57±1.26	11.15±1.23	10.73±0.79

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	24.10±2.49	23.70±1.52	22.52±1.74	22.55±1.63	24.25±1.69
	500	19.47±1.17	18.57±2.27	19.65±1.08	20.37±1.38	19.10±2.39
	1000	9.75±1.50	9.52±1.89	9.50±0.82	11.47±1.89	9.97±1.75
	2000	9.57±3.03	9.62±1.70	9.20±1.24	9.47±1.77	9.55±1.91
	4000	13.10±2.35	14.40±2.03	15.02±1.99	15.35±1.89	14.90±1.78

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	12.15±1.68	12.31±1.61	12.01±1.42	12.40±1.73	12.71±1.31
	500	9.06±1.29	10.13±1.90	9.66±1.40	10.28±1.17	9.96±0.92
	1000	5.10±1.33	5.70±1.26	5.65±0.73	6.53±0.75	5.13±0.94
	2000	4.30±1.46	4.81±0.79	5.00±0.90	5.86±1.17	5.25±0.60
	4000	4.96±0.94	6.80±1.42	5.85±1.16	6.91±1.21	6.30±1.26

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	24.78±1.23	24.16±1.41	24.23±1.55	22.73±1.44	24.03±1.55
	500	19.68±1.19	19.25±1.45	21.33±1.12	20.98±1.36	19.26±2.00
	1000	9.36±1.13	9.51±1.72	9.10±1.16	10.26±1.98	9.08±1.38
	2000	9.05±2.09	9.41±1.39	9.50±1.14	8.13±1.46	8.35±1.59
	4000	14.90±2.63	14.61±1.78	17.30±2.16	15.40±2.23	15.16±1.86

Fonte: Jonas Mendonça Targino. 2019

Tabela 29 – Taxa de reconhecimento da técnica *Fast Robust* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	22.30±1.66	23.04±1.99	22.55±1.13	22.30±1.13	22.02±1.18
	500	19.96±2.14	20.61±1.66	21.05±1.93	21.15±2.18	21.43±1.67
	1000	12.20±1.47	14.10±1.68	14.28±1.87	14.50±0.90	14.68±1.21
	2000	13.95±1.41	14.91±1.48	14.97±1.83	15.22±1.22	15.81±1.36
	4000	20.40±1.80	20.94±1.55	21.24±1.23	21.79±1.68	22.30±1.31

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	25.10±2.40	25.85±3.48	24.75±2.23	24.65±1.55	24.02±2.28
	500	23.07±3.13	22.92±2.44	24.32±2.51	24.10±3.31	24.50±1.95
	1000	13.05±2.21	15.20±2.86	16.27±2.49	17.10±2.80	16.95±2.20
	2000	15.55±2.62	15.62±1.89	16.97±2.38	18.30±1.64	18.15±1.87
	4000	20.42±2.65	20.25±2.23	22.30±2.33	23.90±1.96	24.22±2.52

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	23.26±1.54	24.63±2.39	24.06±1.82	24.05±1.94	24.81±1.86
	500	22.63±1.61	22.65±1.95	23.48±2.18	24.40±2.91	25.35±2.77
	1000	15.76±2.62	18.16±2.40	18.63±3.29	19.66±1.28	20.41±1.84
	2000	17.20±1.80	19.41±2.25	19.65±2.70	20.30±2.77	21.56±2.68
	4000	22.55±3.29	24.21±2.56	24.26±1.45	26.31±2.15	28.16±2.50

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	21.35±2.43	21.45±2.22	21.05±1.88	20.55±2.15	19.23±1.48
	500	17.30±3.14	18.58±2.29	18.63±2.71	17.90±2.69	17.51±1.84
	1000	8.65±1.51	10.05±1.82	9.93±1.80	9.35±1.44	8.95±1.79
	2000	10.70±1.85	10.41±1.48	10.30±1.48	10.15±1.28	10.06±0.89
	4000	18.25±1.96	17.66±1.86	18.21±1.78	17.26±1.95	16.43±1.02

Fonte: Jonas Mendonça Targino. 2019

Tabela 30 – Taxa de reconhecimento da técnica *Gappy* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	62.19±1.38	61.35±1.20	61.13±0.72	61.65±0.79	60.34±0.76
	500	58.94±1.18	58.75±1.31	59.81±0.86	59.08±1.26	56.54±1.40
	1000	42.43±0.91	41.43±1.45	41.77±1.07	40.87±0.69	38.90±1.15
	2000	45.66±0.99	44.67±1.72	45.01±1.13	42.40±1.25	41.47±0.97
	4000	59.60±1.30	59.21±1.56	59.18±1.21	56.47±1.17	55.73±1.35

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	80.40±0.92	77.67±1.72	78.22±1.69	77.35±1.19	75.82±1.22
	500	73.62±1.04	70.65±0.80	72.62±1.85	70.27±1.39	67.85±1.65
	1000	54.92±2.17	51.92±1.92	52.32±1.59	51.32±0.45	50.00±1.49
	2000	57.80±1.15	55.52±2.04	55.90±1.11	53.90±1.18	52.27±1.41
	4000	71.72±1.59	68.30±1.59	69.77±1.61	67.12±1.20	66.35±1.41

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	67.00±2.12	67.05±1.05	66.51±1.04	67.13±1.25	65.78±0.91
	500	67.63±1.87	67.11±1.33	68.53±1.53	67.03±1.33	65.70±1.71
	1000	53.70±1.65	53.85±1.83	53.98±1.51	53.96±1.90	51.73±1.55
	2000	58.98±0.81	58.25±2.14	58.58±1.96	56.86±1.54	55.53±1.53
	4000	71.05±1.60	71.31±1.70	70.50±1.63	69.03±1.54	68.46±1.48

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	57.38±1.45	55.66±2.43	55.75±1.89	56.18±1.88	54.90±1.17
	500	50.25±1.54	50.40±2.31	51.10±1.39	51.13±1.52	47.38±1.91
	1000	31.16±1.10	29.01±2.66	29.56±1.67	27.78±1.18	26.06±1.31
	2000	32.35±1.64	31.10±1.64	31.45±1.14	27.95±2.04	27.41±1.35
	4000	48.15±2.03	47.11±1.92	47.86±1.68	43.91±1.36	43.00±1.88

Fonte: Jonas Mendonça Targino. 2019

Tabela 31 – Taxa de reconhecimento da técnica PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	19.58±1.78	19.70±1.97	19.49±0.62	19.95±1.08	20.55±1.80
	500	16.81±1.54	18.23±1.75	17.84±1.59	19.25±1.29	17.47±2.15
	1000	9.35±1.19	9.40±0.68	9.39±1.27	10.14±1.09	9.15±0.72
	2000	9.43±0.97	10.50±1.77	10.28±1.13	9.85±1.69	9.34±1.38
	4000	14.78±1.79	15.79±0.99	15.24±1.26	13.84±1.47	14.03±0.70

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	23.15±3.10	22.97±2.77	22.97±1.56	23.72±2.13	25.27±2.74
	500	20.67±2.70	22.62±2.11	21.45±2.80	24.22±2.16	22.00±2.99
	1000	11.15±1.58	11.17±1.66	11.47±1.66	12.27±1.58	11.72±1.15
	2000	10.95±2.17	12.75±2.48	12.62±1.75	11.80±2.39	11.77±2.37
	4000	17.07±2.54	18.37±1.79	18.55±1.81	16.07±2.42	16.60±1.32

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	14.61±2.09	15.73±2.01	15.16±1.89	16.13±1.45	16.45±3.13
	500	13.53±2.15	14.23±1.62	14.91±1.77	14.93±1.60	14.73±3.20
	1000	8.81±1.13	9.11±1.67	9.05±1.79	10.40±0.84	9.86±1.05
	2000	9.03±1.61	10.08±1.90	10.48±0.91	10.81±2.32	10.15±2.00
	4000	13.93±2.06	14.65±1.30	14.15±1.58	14.55±1.99	14.51±1.15

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	24.55±2.37	23.66±2.87	23.81±2.37	23.78±2.05	24.66±2.58
	500	20.10±3.01	22.23±2.72	20.76±2.29	23.56±1.59	20.21±2.40
	1000	9.88±1.67	9.68±0.70	9.73±1.52	9.88±1.74	8.43±1.18
	2000	9.83±1.62	10.91±2.07	10.08±2.18	8.88±1.42	8.53±1.44
	4000	15.63±2.17	16.93±1.48	16.33±2.43	13.13±1.69	13.55±1.53

Fonte: Jonas Mendonça Targino. 2019

Tabela 32 – Taxa de reconhecimento da técnica *Recursive* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	70.81±0.96	69.56±1.18	69.45±1.19	68.31±1.10	68.27±1.30
	500	71.61±1.36	71.00±1.72	71.39±0.79	70.95±1.11	69.17±0.96
	1000	51.20±1.03	50.95±1.66	50.40±1.28	50.70±1.02	48.70±1.41
	2000	54.20±1.12	53.32±1.51	53.65±1.47	50.88±1.06	50.18±1.73
	4000	68.14±0.78	69.10±1.25	69.10±0.97	65.45±1.37	64.95±1.24

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	87.97±0.74	86.05±0.80	86.42±1.35	84.85±0.93	83.50±1.30
	500	85.65±0.77	83.97±1.83	85.77±1.03	83.35±0.74	82.10±0.89
	1000	64.92±1.43	63.97±1.56	63.80±1.65	64.00±1.36	61.75±1.16
	2000	68.37±2.56	66.72±1.55	66.00±1.07	63.50±1.47	62.62±2.27
	4000	79.62±1.28	79.27±1.48	80.17±1.45	76.35±1.11	76.15±0.97

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	78.31±1.14	77.68±1.39	77.36±1.92	76.36±1.79	76.43±1.77
	500	83.50±2.08	82.43±0.93	83.70±1.42	82.41±1.12	81.91±1.31
	1000	66.75±1.44	66.61±1.94	65.96±1.91	67.08±1.77	64.98±1.58
	2000	70.58±2.06	70.31±1.92	70.25±2.29	68.90±1.73	67.56±2.28
	4000	82.43±1.10	83.51±1.30	83.23±0.58	81.21±1.76	80.58±1.50

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	63.31±1.12	61.45±3.12	61.55±1.65	60.26±1.67	60.11±2.13
	500	59.73±1.28	59.58±3.26	59.08±1.36	59.50±1.41	56.43±1.51
	1000	35.65±1.12	35.28±1.64	34.85±1.96	34.31±1.76	32.43±1.79
	2000	37.81±1.85	36.33±1.63	37.06±1.85	32.86±1.41	32.80±2.10
	4000	53.85±1.46	54.70±1.49	54.96±1.60	49.68±1.42	49.31±1.51

Fonte: Jonas Mendonça Targino. 2019

Tabela 33 – Taxa de reconhecimento da Representação Esparsa com *Fast Recursive PCA* na base de dados AR com ELM com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	87.55±0.47	87.45±0.48	87.10±0.35	87.01±0.20	87.40±0.49
	500	87.86±0.46	88.05±0.20	87.62±0.27	87.71±0.23	87.96±0.38
	1000	85.33±0.39	85.86±0.49	85.40±0.32	85.00±0.73	85.41±0.70
	2000	86.28±0.41	86.44±0.33	86.20±0.59	85.71±0.47	86.40±0.44
	4000	88.74±0.41	88.73±0.40	89.02±0.21	88.30±0.33	88.42±0.22

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	93.70±0.51	93.32±0.50	93.62±0.39	93.50±0.39	93.35±0.41
	500	93.77±0.24	93.60±0.33	93.45±0.40	93.42±0.40	93.57±0.40
	1000	93.40±0.55	93.22±0.44	93.25±0.37	93.15±0.48	93.12±0.47
	2000	93.92±0.33	93.50±0.56	93.50±0.48	93.27±0.41	93.60±0.45
	4000	94.27±0.38	93.52±0.44	94.20±0.40	93.70±0.32	94.02±0.34

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.45±0.20	95.43±0.28	95.71±0.13	95.6±0.195	95.45±0.17
	500	95.38±0.15	95.43±0.25	95.43±0.16	95.55±0.23	95.40±0.31
	1000	95.33±0.27	95.31±0.29	95.40±0.29	95.31±0.22	95.23±0.36
	2000	95.48±0.30	95.31±0.40	95.53±0.21	95.53±0.46	95.55±0.33
	4000	95.93±0.21	95.45±0.23	96.05±0.24	95.90±0.27	95.61±0.20

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
	200	79.66±1.00	79.48±0.95	78.50±0.68	78.43±0.43	79.36±0.97
	500	80.35±0.90	80.66±0.42	79.81±0.52	79.88±0.52	80.53±0.61
	1000	75.33±0.81	76.41±0.85	75.40±0.56	74.68±1.45	75.60±1.31
	2000	77.08±0.90	77.56±0.66	76.88±1.10	75.90±0.89	77.26±0.82
	4000	81.55±0.76	82.01±0.66	82.00±0.39	80.70±0.58	81.23±0.52

Fonte: Jonas Mendonça Targino. 2019

ELM nível LL2

Tabela 34 – Taxa de reconhecimento da base ocluída com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	35.80±1.37	39.31±3.26	36.60±4.25	36.62±3.34	35.78±3.02
	500	45.23±1.42	47.04±2.66	47.05±2.29	44.78±2.87	45.71±1.86
	1000	34.23±1.95	34.86±1.84	34.08±1.75	33.77±2.39	33.47±2.01
	2000	37.20±1.35	40.60±1.43	39.15±1.74	37.60±2.30	40.25±1.57
	4000	56.51±1.80	59.80±2.29	59.02±1.20	57.78±2.20	58.33±1.59

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	43.07±1.28	46.02±3.53	43.82±4.44	43.60±2.94	43.02±3.03
	500	54.17±2.72	55.62±3.32	57.47±2.48	52.97±3.32	53.97±2.05
	1000	41.30±2.96	41.22±2.65	42.15±3.37	41.05±3.22	39.50±3.63
	2000	43.92±2.40	48.52±2.33	46.70±2.04	44.37±2.91	47.10±2.03
	4000	64.37±2.15	65.97±2.45	66.70±1.47	64.72±2.84	65.42±2.22

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	35.51±3.01	39.03±3.06	35.71±5.24	36.76±5.18	35.48±4.05
	500	42.85±3.19	43.71±2.96	42.78±3.34	43.20±4.84	44.85±3.80
	1000	33.36±2.83	36.18±1.75	33.18±2.33	36.23±2.64	36.33±2.97
	2000	38.78±1.16	42.91±1.94	41.31±2.41	42.56±3.32	44.01±2.29
	4000	58.93±3.18	63.65±2.58	60.06±1.47	62.68±3.06	63.70±1.89

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	36.10±1.99	39.60±4.52	37.48±7.32	36.48±2.73	36.08±3.40
	500	47.61±2.44	50.36±4.57	51.31±3.19	46.36±2.20	46.58±2.45
	1000	35.10±3.45	33.55±3.16	34.98±3.47	31.31±4.25	30.61±3.24
	2000	35.63±2.90	38.30±1.99	37.00±3.13	32.65±2.89	36.50±2.91
	4000	54.10±2.64	55.96±3.28	57.98±1.69	52.88±2.75	52.96±2.89

Fonte: Jonas Mendonça Targino. 2019

Tabela 35 – Taxa de reconhecimento da técnica *Asymmetrical PCA* com ELM nos quatro grupos da base AR com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	30.51±1.36	34.45±3.34	31.22±4.30	31.80±2.94	30.69±3.28
	500	40.15±1.56	40.88±2.66	40.48±2.59	39.94±3.07	40.72±2.38
	1000	31.73±2.49	32.34±1.67	32.12±1.38	31.06±2.91	31.42±1.61
	2000	34.99±2.03	37.00±2.09	36.52±1.47	35.39±2.05	37.30±1.37
	4000	49.96±2.35	53.68±2.46	52.05±1.79	51.71±2.78	53.08±2.02

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	36.55±1.21	40.75±4.12	37.87±5.20	38.12±2.86	37.22±3.64
	500	48.37±2.15	49.02±3.06	50.80±3.97	48.87±3.06	49.77±2.37
	1000	38.42±4.16	38.22±2.49	38.92±3.62	38.22±3.76	38.45±2.83
	2000	41.97±2.84	44.10±2.93	44.37±2.36	42.15±3.32	44.30±1.67
	4000	57.25±3.17	60.42±3.02	59.82±1.88	59.17±3.32	60.62±2.63

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	32.96±2.98	37.45±3.19	33.31±4.64	34.41±5.36	33.05±4.03
	500	41.36±3.59	41.41±3.52	40.06±2.18	41.45±4.92	42.70±3.61
	1000	33.78±3.40	36.36±1.67	34.10±3.03	35.43±2.75	35.86±2.28
	2000	38.36±1.71	41.71±1.78	40.81±2.72	41.31±3.30	42.61±2.60
	4000	55.58±2.58	60.30±3.43	57.08±2.06	58.48±3.20	59.26±2.91

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	28.06±1.87	31.46±4.79	29.13±6.66	29.20±2.49	28.33±4.02
	500	38.93±2.88	40.35±5.07	40.90±4.95	38.43±2.77	38.75±3.56
	1000	29.68±5.13	28.31±3.01	30.15±3.51	26.70±4.16	26.98±3.29
	2000	31.61±4.17	32.30±3.28	32.23±3.10	29.46±3.16	32.00±2.73
	4000	44.35±3.36	47.06±2.61	47.01±2.32	44.95±3.66	46.90±2.84

Fonte: Jonas Mendonça Targino. 2019

Tabela 36 – Taxa de reconhecimento da técnica PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	17.60±1.96	20.78±2.75	19.78±3.15	20.80±2.28	19.40±1.52
	500	18.86±1.06	20.00±1.94	20.13±2.99	19.78±1.61	18.99±1.71
	1000	15.40±1.40	14.20±1.71	14.60±1.94	14.07±1.52	13.76±1.56
	2000	14.68±2.11	16.10±1.59	15.98±0.94	15.25±1.47	15.28±1.58
	4000	18.80±1.48	20.58±1.22	20.55±1.18	19.96±1.55	19.85±1.19

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	20.15±3.16	25.17±4.56	24.05±4.36	25.57±3.44	23.22±2.87
	500	22.55±1.79	24.37±2.71	24.75±4.63	23.55±2.50	23.85±3.50
	1000	19.27±2.82	16.75±1.98	17.75±3.27	17.50±2.60	17.05±2.55
	2000	17.42±2.65	19.42±2.31	18.87±1.11	18.90±1.65	18.72±2.30
	4000	20.70±2.22	23.52±2.10	23.80±2.15	23.12±1.83	22.75±1.80

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	14.43±2.78	18.63±3.42	15.96±1.85	19.10±2.80	17.36±2.42
	500	15.46±2.27	15.73±2.51	15.13±2.20	16.28±1.15	15.46±2.28
	1000	14.36±2.13	12.95±3.01	12.28±2.57	13.10±2.25	12.23±1.65
	2000	12.80±3.10	13.85±2.76	13.68±1.99	14.73±2.73	13.08±1.67
	4000	15.88±2.19	17.51±2.35	15.98±1.44	17.45±1.86	16.30±1.36

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	20.76±2.49	22.93±3.40	23.60±5.03	22.50±2.49	21.43±1.93
	500	22.26±2.43	24.26±2.74	25.13±4.54	23.28±2.82	22.51±2.77
	1000	16.43±2.25	15.46±2.52	16.91±2.18	15.05±2.08	15.30±2.45
	2000	16.56±3.02	18.36±2.14	18.28±2.33	15.76±2.46	17.48±2.74
	4000	21.73±2.35	23.65±2.33	25.11±2.12	22.48±2.74	23.40±1.74

Fonte: Jonas Mendonça Targino. 2019

Tabela 37 – Taxa de reconhecimento da técnica Fisherfaces com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	17.02±1.67	18.43±1.19	18.36±1.83	18.51±1.99	16.95±1.37
	500	18.10±1.06	18.18±1.22	17.89±0.82	17.68±1.06	16.67±0.79
	1000	12.88±0.93	12.35±1.30	12.20±1.43	12.40±0.92	11.05±1.56
	2000	11.58±1.68	12.90±0.84	12.30±1.44	12.12±1.24	11.67±1.13
	4000	16.52±0.65	17.08±0.64	17.19±1.30	17.19±1.12	16.01±0.78

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	21.57±2.78	24.37±2.81	24.17±2.59	23.60±2.84	22.22±2.51
	500	23.50±1.97	22.97±1.32	23.10±1.48	22.90±1.50	21.45±1.19
	1000	16.17±1.59	16.70±2.00	16.82±2.66	16.42±1.92	14.35±2.26
	2000	14.65±2.05	17.07±1.50	16.80±2.21	16.32±1.60	15.12±2.54
	4000	21.65±1.19	22.40±1.07	22.77±1.63	23.32±1.61	21.22±1.67

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	9.85±2.09	12.03±1.51	11.41±2.12	13.20±1.51	10.95±1.90
	500	11.36±1.87	11.65±1.67	10.78±1.76	11.13±1.37	11.05±1.28
	1000	8.8±0.80	8.43±1.56	8.20±1.38	9.65±1.88	7.45±1.53
	2000	6.96±1.73	7.85±1.78	7.33±1.15	7.45±1.89	7.41±1.81
	4000	8.00±1.27	8.58±0.86	8.30±0.97	9.13±1.49	8.13±0.61

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	24.20±1.99	24.83±1.61	25.31±2.46	23.83±2.95	22.96±2.86
	500	24.85±1.28	24.71±1.96	25.00±1.89	24.23±2.05	22.30±1.74
	1000	16.96±1.43	16.28±1.33	16.21±1.76	15.16±2.14	14.65±3.06
	2000	16.20±2.44	17.96±0.94	17.28±2.66	16.80±2.10	15.93±1.79
	4000	25.05±1.18	25.58±0.75	26.08±2.36	25.25±1.60	23.90±1.48

Fonte: Jonas Mendonça Targino. 2019

Tabela 38 – Taxa de reconhecimento da técnica *Fast Robust* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	23.64±1.21	24.04±1.65	24.75±0.81	23.79±2.58	23.65±2.44
	500	22.65±1.21	22.48±1.92	23.30±1.54	22.39±1.40	22.13±1.70
	1000	17.44±0.92	17.46±1.19	17.63±1.46	17.00±2.17	16.89±1.52
	2000	17.99±1.28	19.04±1.38	19.48±1.88	19.23±1.69	18.65±1.86
	4000	24.41±1.18	25.10±1.49	26.45±1.32	25.87±0.57	25.61±1.36

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	25.52±2.54	25.67±3.34	27.35±2.36	25.82±4.33	25.87±3.17
	500	25.52±1.99	24.82±3.18	25.72±1.93	25.17±1.98	25.05±2.90
	1000	21.22±1.67	20.77±2.14	20.52±1.55	20.27±3.54	20.05±1.67
	2000	21.17±1.88	20.00±2.40	21.77±2.59	22.37±3.36	21.12±3.21
	4000	26.92±1.33	24.90±2.39	27.70±2.17	28.10±1.56	27.05±2.25

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	25.70±1.85	26.93±2.26	26.61±1.91	25.91±2.51	27.21±2.81
	500	24.38±1.72	25.06±1.78	24.66±2.45	23.93±1.83	24.76±3.14
	1000	19.88±1.77	21.23±1.82	20.60±2.22	20.01±3.44	20.65±2.27
	2000	22.26±2.38	21.90±2.23	23.08±2.86	23.10±2.31	23.06±2.24
	4000	26.56±1.78	26.86±2.25	28.26±1.49	27.80±1.15	28.36±1.53

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	21.58±1.73	21.15±2.49	22.88±2.71	21.66±3.93	20.08±2.63
	500	20.93±2.35	19.90±2.81	21.95±2.35	20.85±1.80	19.50±1.84
	1000	15.00±1.76	13.70±2.12	14.66±1.87	13.98±2.15	13.13±1.25
	2000	13.71±2.61	16.18±2.42	15.88±1.92	15.36±1.44	14.23±2.61
	4000	22.26±1.20	23.33±1.61	24.63±2.15	23.95±1.80	22.86±2.40

Fonte: Jonas Mendonça Targino. 2019

Tabela 39 – Taxa de reconhecimento da técnica *Gappy* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	59.16±0.83	60.15±1.53	60.58±1.90	59.26±1.03	58.75±2.10
	500	62.34±1.32	62.00±1.53	62.99±1.11	61.93±0.95	60.81±1.27
	1000	53.50±1.44	51.22±1.61	53.40±1.09	51.73±1.13	49.84±0.89
	2000	57.12±1.57	56.50±0.98	57.53±1.22	56.45±1.56	55.23±1.14
	4000	67.87±1.13	67.82±0.66	68.72±0.67	67.44±1.13	66.94±0.66

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	76.52±1.99	76.80±1.93	77.80±1.07	74.82±1.85	75.15±1.69
	500	78.55±1.26	77.32±1.41	78.05±1.05	76.42±1.15	75.32±1.53
	1000	67.40±2.01	64.75±2.16	66.90±2.13	64.92±1.15	62.80±1.63
	2000	71.30±1.35	69.82±1.44	70.87±1.41	68.82±1.80	68.17±1.57
	4000	80.22±1.10	78.52±1.07	79.47±0.78	78.22±1.21	77.87±0.84

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	65.08±2.42	65.78±1.71	66.28±1.80	65.31±0.96	65.21±2.41
	500	68.63±1.42	68.80±1.53	69.23±1.09	68.31±1.23	68.78±1.89
	1000	61.65±2.40	60.65±1.28	62.00±2.41	61.41±1.75	60.13±1.81
	2000	66.05±1.44	66.15±2.03	66.48±2.21	66.96±1.47	65.83±2.43
	4000	76.23±1.22	76.50±0.96	76.60±0.81	76.60±1.27	75.96±0.82

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	53.25±1.77	54.53±2.27	54.88±2.90	53.21±1.49	52.28±2.64
	500	56.05±1.84	55.20±1.94	56.75±2.24	55.55±2.00	52.85±1.71
	1000	45.36±1.76	41.80±2.58	44.80±1.79	42.05±1.73	39.55±1.15
	2000	48.20±2.94	46.85±1.56	48.58±1.50	45.93±1.93	44.63±1.38
	4000	59.51±1.69	59.15±1.01	60.85±0.92	58.28±1.52	57.91±0.88

Fonte: Jonas Mendonça Targino. 2019

Tabela 40 – Taxa de reconhecimento da técnica *Fast Recursive PCA* com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	65.20±1.08	66.01±1.26	66.19±2.17	65.26±1.37	64.31±2.17
	500	74.01±1.26	74.01±1.71	75.17±1.03	73.50±0.99	72.29±0.76
	1000	63.81±1.47	62.20±1.56	62.99±0.85	63.05±1.10	61.36±1.27
	2000	68.23±0.94	68.19±1.34	68.76±1.16	66.92±1.39	67.16±1.13
	4000	81.05±0.81	81.58±0.66	81.85±0.55	80.96±0.81	80.70±0.76

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	82.65±1.39	82.10±2.00	82.40±1.24	81.40±2.57	81.27±1.63
	500	89.27±0.75	87.60±1.74	88.37±0.91	86.55±1.67	85.92±1.13
	1000	79.82±1.72	77.65±1.19	78.37±1.00	77.15±1.91	76.57±2.26
	2000	82.95±2.06	81.22±1.42	82.67±0.91	80.57±1.51	80.70±1.37
	4000	91.57±0.82	89.80±0.46	90.22±1.09	89.82±0.69	89.35±1.10

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	72.50±2.21	73.45±0.96	73.41±1.92	73.13±1.53	71.70±2.74
	500	82.23±1.19	82.00±1.29	82.53±1.17	81.83±1.45	80.75±1.24
	1000	74.26±1.59	73.30±1.37	73.10±1.60	74.83±1.96	73.68±1.97
	2000	78.86±1.15	79.50±1.38	80.25±1.53	80.06±1.17	79.21±1.68
	4000	89.33±0.84	89.76±0.83	89.71±0.72	89.63±0.80	89.36±0.77

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	57.91±1.67	58.58±2.27	58.96±4.00	57.40±1.81	56.93±2.44
	500	65.80±2.03	66.03±2.43	67.81±1.70	65.16±1.77	63.83±1.23
	1000	53.36±2.18	51.10±2.50	52.88±2.54	51.26±1.23	49.05±1.32
	2000	57.60±1.51	56.88±2.12	57.28±1.75	53.78±2.43	55.11±1.85
	4000	72.78±1.17	73.40±1.37	74.00±0.75	72.30±1.47	72.03±1.35

Fonte: Jonas Mendonça Targino. 2019

Tabela 41 – Taxa de reconhecimento da técnica *Recursive* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	65.25±1.12	66.00±1.28	66.25±2.22	65.24±1.36	64.36±2.15
	500	74.01±1.29	74.06±1.67	75.15±1.05	73.55±0.96	72.36±0.73
	1000	63.82±1.52	62.20±1.60	62.97±0.83	63.05±1.13	61.37±1.33
	2000	68.22±0.96	68.21±1.32	68.75±1.15	66.93±1.36	67.20±1.09
	4000	81.09±0.78	81.59±0.64	81.87±0.54	81.01±0.76	80.70±0.77

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	82.75±1.29	82.10±1.87	82.55±1.32	81.45±2.57	81.32±1.52
	500	89.30±0.79	87.70±1.59	88.37±0.96	86.70±1.61	86.07±1.06
	1000	79.87±1.93	77.65±1.23	78.32±0.95	77.22±1.92	76.62±2.39
	2000	82.90±2.04	81.22±1.34	82.65±0.89	80.62±1.57	80.75±1.30
	4000	91.62±0.78	89.90±0.61	90.30±1.07	89.92±0.71	89.37±1.10

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	72.55±2.23	73.45±0.96	73.48±1.91	73.13±1.53	71.78±2.77
	500	82.28±1.21	82.05±1.25	82.50±1.15	81.91±1.50	80.86±1.23
	1000	74.28±1.61	73.33±1.35	73.10±1.55	74.86±1.94	73.76±2.03
	2000	78.86±1.15	79.51±1.38	80.28±1.50	80.10±1.23	79.36±1.74
	4000	89.36±0.84	89.76±0.86	89.73±0.71	89.61±0.82	89.40±0.79

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	57.95±1.67	58.55±2.30	59.03±4.07	57.35±1.75	56.95±2.38
	500	65.75±2.01	66.08±2.42	67.81±1.70	65.20±1.84	63.86±1.14
	1000	53.36±2.35	51.08±2.56	52.85±2.49	51.25±1.42	48.98±1.35
	2000	57.58±1.56	56.91±2.12	57.21±1.76	53.76±2.34	55.05±1.78
	4000	72.81±1.12	73.41±1.35	74.01±0.75	72.41±1.44	72.01±1.36

Fonte: Jonas Mendonça Targino. 2019

Tabela 42 – Taxa de reconhecimento da SRC com *Fast Recursive PCA* na base de dados AR com ELM com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	87.58±0.42	87.41±0.32	87.66±0.58	87.47±0.50	87.20±0.44
	500	89.10±0.46	88.88±0.24	89.13±0.54	88.75±0.48	88.78±0.38
	1000	87.11±0.39	87.25±0.68	87.46±0.64	87.42±0.53	87.25±0.61
	2000	88.21±0.35	88.45±0.38	88.39±0.50	88.12±0.54	88.23±0.35
	4000	89.83±0.21	89.85±0.23	89.88±0.26	89.72±0.19	89.52±0.16

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	93.52±0.34	93.35±0.48	93.62±0.24	93.05±0.48	93.25±0.39
	500	94.37±0.50	93.92±0.39	94.05±0.28	93.75±0.31	93.75±0.40
	1000	94.17±0.23	93.97±0.34	93.97±0.32	93.95±0.34	94.00±0.23
	2000	94.75±0.35	94.45±0.38	94.17±0.26	94.12±0.37	94.32±0.28
	4000	94.67±0.26	94.65±0.21	94.45±0.22	94.25±0.23	94.35±0.29

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.55±0.26	95.46±0.25	95.46±0.13	95.36±0.21	95.40±0.35
	500	95.70±0.23	95.56±0.21	95.70±0.17	95.58±0.25	95.61±0.28
	1000	95.58±0.18	95.51±0.18	95.43±0.23	95.61±0.34	95.58±0.22
	2000	95.83±0.24	95.78±0.26	95.58±0.25	95.83±0.27	95.78±0.19
	4000	95.88±0.11	95.96±0.17	95.78±0.15	95.96±0.13	96.01±0.12

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
	200	79.61±0.88	79.36±0.52	79.86±1.15	79.58±0.92	79.00±0.87
	500	82.50±0.85	82.20±0.42	82.56±1.18	81.93±0.96	81.95±0.77
	1000	78.65±0.75	78.98±1.32	79.50±1.23	79.23±1.00	78.91±1.17
	2000	80.60±0.65	81.13±0.70	81.20±1.11	80.41±1.08	80.68±0.69
	4000	83.78±0.41	83.73±0.45	83.98±0.49	83.48±0.39	83.03±0.28

Fonte: Jonas Mendonça Targino. 2019

ELM nível LL1

Tabela 43 – Taxa de reconhecimento da base ocluída com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	29.81±3.20	27.80±2.95	28.53±0.97	27.68±2.30	30.47±2.68
	500	37.60±2.07	35.40±2.08	36.20±2.83	36.17±4.28	37.45±2.28
	1000	28.16±1.27	27.00±1.94	27.65±2.01	28.38±1.27	27.50±1.84
	2000	35.20±3.36	35.50±1.71	35.28±3.09	34.78±3.73	35.29±2.04
	4000	54.79±1.90	53.39±2.66	55.46±3.43	54.80±2.34	54.16±2.52

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	35.52±4.22	33.20±3.55	34.27±1.98	33.27±2.85	36.32±2.36
	500	45.30±3.56	41.42±3.17	43.72±4.54	43.42±5.42	44.55±3.45
	1000	33.92±2.70	32.15±3.25	33.30±2.40	33.62±2.85	33.15±2.35
	2000	40.45±4.67	40.67±2.20	40.12±2.70	39.45±4.59	41.22±3.81
	4000	59.85±2.97	59.47±3.60	61.92±3.92	62.00±2.56	59.725±4.35

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	31.28±3.38	29.05±4.19	30.13±4.12	29.71±4.00	33.50±4.63
	500	36.95±1.56	34.30±2.93	37.28±3.23	37.60±3.69	37.88±2.23
	1000	27.78±2.17	27.05±3.37	28.08±3.73	28.55±2.81	29.58±2.77
	2000	35.65±3.72	37.68±2.42	36.68±4.69	37.03±4.85	37.25±2.37
	4000	56.21±2.45	54.68±3.89	57.58±4.62	56.38±2.75	57.45±3.44

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	28.35±4.14	26.56±4.14	26.93±3.90	25.65±5.27	27.45±4.34
	500	38.26±3.05	36.51±4.14	35.11±4.70	34.75±6.06	37.01±5.02
	1000	28.55±1.97	26.95±2.19	27.21±3.53	28.21±3.36	25.41±2.01
	2000	34.76±3.98	33.33±2.20	33.88±2.85	32.53±4.63	33.33±3.22
	4000	53.36±3.74	52.10±3.60	53.35±2.99	53.21±4.74	50.88±3.22

Fonte: Jonas Mendonça Targino. 2019

Tabela 44 – Taxa de reconhecimento da técnica *Asymmetrical* PCA com ELM nos quatro grupos da base AR com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	25.40±2.96	23.37±2.64	24.20±1.58	23.91±1.80	26.30±2.63
	500	32.99±2.51	30.66±2.21	30.75±3.31	31.30±4.01	32.74±2.74
	1000	25.93±1.90	25.10±1.84	26.04±2.49	26.68±1.43	25.66±1.85
	2000	31.34±2.71	32.76±2.18	32.23±2.96	32.39±2.95	31.85±2.23
	4000	46.31±2.13	45.31±2.25	47.36±3.02	46.71±2.36	46.44±2.25

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	30.40±3.82	27.97±3.00	28.85±2.34	28.62±2.50	31.05±2.28
	500	39.97±4.13	35.92±3.37	36.90±4.53	37.92±5.35	38.92±3.84
	1000	31.25±2.18	30.65±2.35	31.17±2.76	31.85±2.61	31.32±1.57
	2000	36.60±4.22	38.17±3.01	37.50±4.10	37.17±3.86	37.55±3.92
	4000	52.00±3.63	51.05±3.49	53.75±3.92	53.42±3.12	52.62±3.19

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	29.21±3.24	26.86±4.36	28.75±3.99	28.78±4.58	31.93±5.23
	500	35.48±2.36	33.23±3.46	34.76±3.25	36.00±3.70	35.51±2.17
	1000	27.91±3.51	27.00±2.51	29.08±4.08	29.73±2.56	29.68±2.97
	2000	35.15±3.35	38.06±2.16	36.71±3.97	37.30±4.39	36.28±3.76
	4000	52.46±2.54	51.28±2.58	53.40±4.52	52.83±2.70	53.33±2.52

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	21.60±3.71	19.88±3.22	19.65±4.03	19.05±3.93	20.68±3.93
	500	30.50±3.74	28.10±4.57	26.75±5.73	26.60±5.50	29.96±5.52
	1000	23.95±1.48	23.20±3.06	23.00±3.55	23.63±3.25	21.65±2.17
	2000	27.53±3.94	27.46±3.75	27.75±3.97	27.48±4.32	27.41±2.09
	4000	40.16±4.15	39.35±4.33	41.33±2.95	40.60±4.78	39.55±3.20

Fonte: Jonas Mendonça Targino. 2019

Tabela 45 – Taxa de reconhecimento da técnica PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	17.40±2.03	15.80±2.05	16.32±1.74	16.45±1.20	17.58±1.91
	500	18.60±1.17	17.50±2.04	17.00±1.58	17.56±2.00	19.01±2.78
	1000	13.99±1.39	13.52±1.31	13.94±1.05	14.02±1.25	13.60±1.07
	2000	16.16±1.56	14.50±1.57	15.72±1.46	15.79±1.48	15.60±1.34
	4000	19.88±1.07	19.10±1.72	19.90±1.18	18.65±1.12	19.53±1.68

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	21.35±3.00	18.87±3.52	19.92±2.92	19.72±2.47	21.80±2.18
	500	22.90±2.14	21.02±2.84	20.35±2.06	21.70±2.64	23.27±4.58
	1000	17.50±2.56	16.87±2.01	16.50±1.98	17.75±2.45	16.65±1.36
	2000	19.25±2.80	17.22±2.53	18.90±2.29	18.92±2.00	18.85±2.19
	4000	22.95±1.88	21.57±2.55	22.72±2.39	21.17±1.65	22.85±2.47

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	16.71±3.23	15.66±3.30	15.88±1.73	16.73±2.84	18.00±2.81
	500	16.90±2.34	16.23±2.76	16.38±1.87	17.36±2.49	17.60±3.32
	1000	14.18±1.77	12.35±1.97	13.63±2.60	13.50±1.61	12.71±2.32
	2000	15.65±1.41	13.23±2.12	15.73±3.04	15.80±2.86	14.83±2.80
	4000	18.95±1.12	17.38±1.44	18.35±2.42	17.16±2.01	17.81±2.08

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	18.10±2.66	15.93±3.16	16.76±3.13	16.18±3.19	17.16±1.98
	500	20.31±1.85	18.78±4.47	17.61±3.99	17.76±3.30	20.43±4.09
	1000	13.80±1.71	14.70±2.23	14.25±1.83	14.55±2.54	14.48±1.92
	2000	16.68±2.59	15.78±2.33	15.71±1.97	15.78±1.96	16.38±1.79
	4000	20.81±2.45	20.81±2.66	21.46±2.52	20.15±2.09	21.25±2.62

Fonte: Jonas Mendonça Targino. 2019

Tabela 46 – Taxa de reconhecimento da técnica Fisherfaces com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	15.67±1.58	14.71±1.23	15.11±1.51	15.14±1.89	15.52±1.58
	500	15.72±1.70	15.68±0.90	15.53±1.31	16.30±1.27	15.85±1.20
	1000	10.99±1.02	10.88±1.07	10.98±1.19	10.84±1.25	10.59±1.31
	2000	12.23±1.43	11.57±1.82	12.95±0.94	12.61±1.06	12.25±1.54
	4000	17.44±1.01	16.93±1.08	17.44±1.09	17.00±1.16	16.56±1.39

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	20.05±1.81	19.20±1.40	19.12±3.05	19.22±1.92	20.22±2.41
	500	19.85±2.87	20.82±2.05	19.55±1.48	20.57±2.27	20.60±2.32
	1000	15.22±1.99	14.17±1.74	14.95±1.70	14.87±1.88	13.17±2.44
	2000	16.15±2.18	14.87±3.56	16.95±2.00	16.52±1.55	16.37±2.93
	4000	23.15±1.48	22.37±1.54	22.57±1.82	21.37±2.72	22.10±1.64

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	10.10±2.24	9.56±3.02	9.96±1.87	10.31±1.51	10.53±1.78
	500	10.43±2.19	9.18±1.09	8.66±1.34	10.48±1.24	10.75±1.51
	1000	7.60±1.12	7.73±1.70	7.38±2.14	7.80±1.40	8.13±2.26
	2000	8.23±1.20	7.21±1.61	8.33±2.00	8.76±1.55	8.71±2.41
	4000	9.30±1.22	8.88±1.02	9.28±1.51	9.48±1.18	9.18±1.06

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	21.25±1.99	19.86±2.30	20.26±2.23	19.96±3.71	20.51±2.65
	500	21.01±1.85	22.18±1.87	22.40±2.19	22.13±2.89	20.95±2.20
	1000	14.38±1.96	14.03±1.50	14.58±1.46	13.88±2.33	13.05±1.87
	2000	16.23±2.58	15.93±3.26	17.58±1.23	16.46±2.36	15.78±1.36
	4000	25.58±1.47	24.98±1.56	25.60±1.54	24.51±2.46	23.95±2.23

Fonte: Jonas Mendonça Targino. 2019

Tabela 47 – Taxa de reconhecimento da técnica *Fast Robust* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	22.09±1.84	22.08±1.87	22.41±2.00	22.96±2.95	22.03±1.81
	500	21.61±1.55	21.94±1.54	21.53±2.27	23.50±0.93	21.89±1.04
	1000	16.81±1.23	16.37±0.56	16.13±1.63	15.92±1.99	15.90±1.55
	2000	19.13±1.95	19.75±1.49	18.20±0.99	19.53±0.85	19.40±1.68
	4000	25.99±1.64	25.83±1.25	26.03±2.00	26.92±1.72	26.55±1.62

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	25.17±2.80	24.37±2.70	24.10±2.83	25.87±3.77	24.47±2.63
	500	24.32±2.77	24.67±2.46	24.50±3.52	27.02±2.33	24.17±1.49
	1000	20.10±2.21	18.82±0.95	18.82±2.92	18.17±2.98	18.35±2.27
	2000	21.77±2.35	21.30±3.32	21.17±2.00	22.55±1.97	22.00±2.07
	4000	28.42±3.07	27.45±1.54	28.07±3.16	29.95±2.22	28.00±2.05

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	25.06±2.18	24.68±2.18	25.71±3.87	25.16±4.07	25.60±3.16
	500	23.93±2.03	24.35±2.21	23.63±2.39	26.81±2.12	25.83±2.39
	1000	20.41±1.96	19.23±1.29	19.45±2.56	18.98±2.92	19.63±2.79
	2000	23.01±2.70	23.58±1.56	21.41±1.60	22.36±1.67	23.01±2.36
	4000	28.56±1.79	27.65±1.71	27.58±2.85	28.38±2.34	29.05±2.13

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	19.11±2.65	19.48±2.64	19.11±2.91	20.76±3.09	18.46±3.01
	500	19.30±1.98	19.53±2.34	19.43±2.79	20.20±2.48	17.76±2.13
	1000	13.21±1.91	13.51±1.38	12.81±2.11	12.86±1.74	12.35±2.00
	2000	15.25±2.03	15.91±2.21	15.00±1.50	16.70±1.34	15.78±1.501
	4000	23.41±2.35	24.01±1.42	24.48±2.72	25.46±2.37	24.06±2.08

Fonte: Jonas Mendonça Targino. 2019

Tabela 48 – Taxa de reconhecimento da técnica *Gappy* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	52.82±1.68	52.17±1.23	53.58±1.81	52.79±1.90	53.73±1.16
	500	58.00±1.17	57.95±1.50	57.67±1.35	58.50±1.36	58.25±1.54
	1000	49.97±1.10	50.32±1.82	49.95±1.95	50.15±1.24	49.84±1.20
	2000	57.14±0.97	57.37±1.04	56.89±1.53	56.71±1.55	56.59±0.96
	4000	67.80±0.84	67.99±0.95	67.86±0.97	67.77±0.96	67.76±1.33

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	70.12±2.12	69.10±1.86	69.55±2.08	70.00±2.81	69.87±2.19
	500	74.22±1.65	74.32±1.81	74.60±1.57	75.17±1.34	74.07±2.28
	1000	63.22±2.00	65.35±2.22	65.85±2.63	64.95±2.12	63.80±1.26
	2000	71.40±1.98	72.10±1.20	71.92±1.74	71.47±1.78	70.70±1.37
	4000	81.87±1.44	81.62±1.42	81.72±0.44	81.37±1.35	80.32±1.30

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	59.36±2.79	59.70±2.43	60.40±2.38	60.45±2.32	61.38±2.26
	500	65.65±2.30	65.98±2.14	65.58±1.19	67.68±1.41	66.53±1.85
	1000	59.08±1.94	59.33±2.06	59.28±2.47	59.51±2.03	60.21±1.66
	2000	66.88±1.78	68.06±1.16	66.63±2.60	67.31±2.15	66.80±0.91
	4000	77.21±0.93	77.68±1.12	77.31±0.69	77.25±1.46	76.86±1.82

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	46.28±2.56	44.65±2.94	46.76±2.69	45.13±2.15	46.08±1.52
	500	50.36±2.79	49.91±2.41	49.76±2.37	49.31±2.93	49.96±1.87
	1000	40.86±1.14	41.31±2.43	40.63±2.41	40.78±2.27	39.46±1.94
	2000	47.40±1.09	46.68±2.04	47.15±1.02	46.11±1.69	46.38±1.42
	4000	58.40±1.80	58.30±1.71	58.41±1.87	58.30±1.16	58.66±1.62

Fonte: Jonas Mendonça Targino. 2019

Tabela 49 – Taxa de reconhecimento da técnica *Fast Recursive PCA* com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	56.77±1.73	54.98±1.22	56.85±1.57	55.75±2.29	56.94±1.16
	500	65.67±1.30	65.06±1.43	64.47±1.28	65.11±2.20	65.32±1.30
	1000	56.10±1.51	56.02±2.02	55.99±1.46	56.18±1.44	55.24±1.13
	2000	65.59±1.18	65.53±0.88	65.65±1.34	64.95±1.41	64.81±1.30
	4000	79.89±1.11	79.40±0.95	79.99±0.89	79.34±0.62	79.74±1.06

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	75.15±1.72	73.12±1.37	74.47±1.85	74.30±2.97	74.32±1.33
	500	81.77±1.36	80.75±1.41	81.35±1.97	81.25±1.26	80.90±1.61
	1000	71.32±1.52	72.25±1.67	72.35±1.96	71.70±1.61	70.75±1.82
	2000	79.85±1.51	79.92±1.54	80.10±1.78	79.32±1.36	79.02±1.52
	4000	90.07±0.85	89.52±1.14	90.42±1.09	89.60±0.92	89.60±0.74

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	64.56±2.45	62.51±1.99	64.68±2.86	64.58±2.45	65.71±1.77
	500	74.31±2.33	73.61±1.72	73.51±1.19	75.38±2.02	74.75±1.12
	1000	65.63±2.36	66.06±2.08	65.50±1.91	66.36±2.62	66.30±1.56
	2000	76.76±0.94	77.18±0.77	76.26±1.63	76.93±1.94	75.86±1.48
	4000	88.35±0.91	88.36±0.61	88.63±0.81	88.23±1.17	88.70±1.36

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	48.98±2.68	47.45±3.44	49.01±2.76	46.93±2.78	48.16±2.06
	500	57.03±2.15	56.51±2.50	55.43±2.17	54.85±4.01	55.90±1.92
	1000	46.58±1.27	45.98±2.58	46.48±2.33	46.00±2.23	44.18±1.43
	2000	54.41±2.31	53.88±1.97	55.05±2.65	52.96±1.74	53.76±1.65
	4000	71.43±2.16	70.43±2.09	71.35±1.99	70.45±1.34	70.78±1.65

Fonte: Jonas Mendonça Targino. 2019

Tabela 50 – Taxa de reconhecimento da técnica *Recursive* PCA com ELM na base de dados AR com oclusões com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	56.79±1.74	55.03±1.27	56.81±1.59	55.83±2.28	56.94±1.17
	500	65.70±1.24	65.17±1.38	64.55±1.29	65.15±2.22	65.33±1.31
	1000	56.19±1.51	56.06±2.02	56.03±1.44	56.20±1.42	55.20±1.11
	2000	65.56±1.25	65.55±0.88	65.70±1.38	64.94±1.41	64.85±1.34
	4000	79.92±1.15	79.43±0.97	79.96±0.82	79.30±0.63	79.78±1.10

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	75.12±1.80	73.17±1.53	74.40±1.89	74.52±2.99	74.32±1.38
	500	81.85±1.38	80.95±1.30	81.45±1.98	81.40±1.35	80.85±1.59
	1000	71.52±1.61	72.35±1.67	72.32±1.84	71.80±1.61	70.80±1.90
	2000	79.77±1.57	79.95±1.42	80.22±1.94	79.27±1.45	79.15±1.57
	4000	90.12±0.92	89.65±1.13	90.35±0.89	89.47±0.94	89.55±0.83

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	64.56±2.43	62.63±1.91	64.61±2.93	64.66±2.52	65.66±1.86
	500	74.36±2.31	73.71±1.68	73.60±1.26	75.43±2.00	74.80±1.15
	1000	65.66±2.30	66.08±2.00	65.56±1.84	66.38±2.58	66.33±1.54
	2000	76.75±0.91	77.25±0.75	76.30±1.60	76.93±1.93	75.98±1.53
	4000	88.40±0.86	88.40±0.56	88.65±0.83	88.21±1.16	88.76±1.37

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	49.01±2.72	47.43±3.51	49.01±2.69	47.00±2.69	48.21±2.03
	500	57.03±2.08	56.63±2.46	55.51±2.13	54.86±4.00	55.86±1.89
	1000	46.71±1.36	46.05±2.64	46.50±2.24	46.01±2.18	44.08±1.44
	2000	54.38±2.38	53.85±2.01	55.11±2.72	52.95±1.70	53.73±1.78
	4000	71.45±2.15	70.46±2.11	71.28±1.93	70.38±1.43	70.80±1.70

Fonte: Jonas Mendonça Targino. 2019

Tabela 51 – Taxa de reconhecimento da SRC com *Fast Recursive PCA* na base de dados AR com ELM com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	86.52±0.59	86.44±0.61	86.44±0.56	86.54±0.44	86.37±0.69
	500	88.34±0.53	88.18±0.59	88.40±0.42	88.35±0.45	88.05±0.34
	1000	86.52±0.51	86.97±0.46	86.79±0.43	87.02±0.64	86.51±0.49
	2000	88.32±0.44	88.53±0.34	88.39±0.30	88.50±0.41	88.33±0.41
	4000	89.75±0.25	89.86±0.21	89.83±0.18	89.85±0.26	89.60±0.22

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	93.47±0.49	93.47±0.47	93.22±0.53	93.35±0.41	93.07±0.28
	500	93.82±0.56	93.80±0.43	93.82±0.48	93.82±0.31	93.75±0.33
	1000	93.87±0.51	93.95±0.36	93.82±0.37	93.97±0.34	93.72±0.43
	2000	94.35±0.41	94.17±0.47	94.12±0.31	94.27±0.38	94.05±0.38
	4000	94.37±0.24	94.42±0.12	94.35±0.12	94.37±0.21	94.30±0.19

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.31±0.37	95.43±0.34	95.31±0.35	95.28±0.47	95.23±0.35
	500	95.41±0.30	95.46±0.13	95.68±0.34	95.61±0.29	95.51±0.28
	1000	95.35±0.26	95.41±0.41	95.23±0.33	95.50±0.29	95.38±0.53
	2000	95.63±0.15	95.70±0.21	95.73±0.19	95.81±0.19	95.68±0.24
	4000	95.91±0.14	95.88±0.13	95.98±0.09	95.96±0.07	95.88±0.13

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	77.73±0.95	77.45±1.08	77.56±0.93	77.80±0.58	77.51±1.16
	500	81.26±1.08	80.90±1.06	81.13±0.72	81.08±0.91	80.60±0.51
	1000	77.70±0.98	78.53±0.77	78.35±0.83	78.55±1.26	77.65±0.84
	2000	81.01±0.95	81.36±0.70	81.05±0.55	81.18±0.83	80.98±0.76
	4000	83.58±0.45	83.85±0.37	83.68±0.40	83.75±0.51	83.33±0.40

Fonte: Jonas Mendonça Targino. 2019

E.1.2 Resultados com KNN

Tabela 52 – Taxa de reconhecimento com KNN na base de dados AR com oclusões com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	42.83	44.25	42.50	39.50	40.25	43.25	43.75	42.00	41.25	42.50
	2	42.83	44.25	42.50	39.50	40.25	43.25	43.75	42.00	41.25	42.50
	4	41.58	43.00	41.92	38.00	38.67	43.25	43.75	42.00	41.25	42.50
	6	39.67	41.75	41.33	37.42	37.83	40.50	42.50	43.75	38.00	37.75
	8	39.33	40.83	40.67	35.92	37.25	41.25	42.50	41.75	35.50	37.75
	10	38.33	40.42	39.17	35.75	36.58	40.25	41.00	41.00	36.00	37.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	72.67	75.83	73.33	69.00	70.83	12.67	12.67	12.17	9.83	10.17
	2	72.67	75.83	73.33	69.00	70.83	12.67	12.67	12.17	9.83	10.17
	4	71.00	72.83	70.50	67.17	68.17	11.67	12.83	12.67	9.33	9.50
	6	68.17	70.83	70.33	65.67	66.17	11.00	12.83	12.83	9.17	9.83
	8	66.33	68.33	68.67	62.50	64.67	11.83	12.67	12.00	8.67	9.67
	10	65.17	68.50	67.33	62.33	63.17	11.67	12.67	11.83	9.00	9.33

Fonte: Jonas Mendonça Targino. 2019

Tabela 53 – Taxa de reconhecimento com KNN na base de dados Yale com oclusões com nível de decomposição LL3

		Yale#1					Yale#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	100.00	100.00	100.00	93.33	100.00	46.67	53.33	46.67	26.67	26.67
	2	100.00	100.00	100.00	93.33	100.00	46.67	53.33	46.67	26.67	26.67
	4	100.00	93.33	100.00	100.00	100.00	46.67	40.00	46.67	33.33	33.33
	6	100.00	100.00	100.00	100.00	100.00	46.67	53.33	46.67	26.67	26.67
	8	93.33	93.33	100.00	100.00	100.00	53.33	53.33	53.33	26.67	26.67
	10	100.00	93.33	100.00	100.00	100.00	53.33	46.67	60.00	26.67	26.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 54 – Taxa de reconhecimento com KNN na base AR com a técnica *Fast Recursive PCA* com nível de decomposição LL3

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	53.08	47.83	50.17	42.17	41.42	56.00	50.50	52.00	42.50	42.75
	2	53.08	47.83	50.17	42.17	41.42	56.00	50.50	52.00	42.50	42.75
	4	51.42	47.33	48.42	41.08	40.58	55.25	49.50	49.50	40.75	41.75
	6	51.00	46.42	48.58	40.33	40.67	55.00	48.25	49.50	42.50	41.75
	8	50.00	44.83	48.17	39.50	39.17	55.25	47.00	49.00	41.75	41.75
	10	48.83	43.83	46.42	38.33	37.92	55.00	47.25	49.25	40.75	41.75

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	79.83	71.50	75.00	65.50	64.67	26.33	24.17	25.33	18.83	18.17
	2	79.83	71.50	75.00	65.50	64.67	26.33	24.17	25.33	18.83	18.17
	4	76.50	69.00	71.67	63.33	62.17	26.33	25.67	25.17	18.83	19.00
	6	76.83	68.00	72.00	62.00	61.50	25.17	24.83	25.17	18.67	19.83
	8	75.67	65.83	71.00	60.83	59.67	24.33	23.83	25.33	18.17	18.67
	10	72.67	63.33	67.83	58.33	56.83	25.00	24.33	25.00	18.33	19.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 55 – Taxa de reconhecimento com KNN na base AR com a técnica Fisherfaces com nível de decomposição LL3

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	8.17	5.83	6.17	5.00	4.92	8.50	5.25	6.50	5.25	5.50
	2	8.17	5.83	6.17	5.00	4.92	8.50	5.25	6.50	5.25	5.50
	4	8.50	5.83	6.67	5.17	5.25	8.75	5.75	6.50	5.75	6.25
	6	8.67	5.33	6.92	5.17	5.17	9.00	4.75	7.25	5.50	6.50
	8	9.08	5.58	7.00	5.08	4.92	9.50	5.00	7.25	6.00	6.75
	10	8.58	4.92	7.25	5.08	4.42	8.50	4.75	7.25	6.75	6.25

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	6.33	4.50	5.67	4.33	4.17	10.00	7.17	6.67	5.67	5.67
	2	6.33	4.50	5.67	4.33	4.17	10.00	7.17	6.67	5.67	5.67
	4	6.67	5.00	6.00	4.50	4.67	10.33	6.67	7.33	5.83	5.83
	6	7.17	4.67	6.00	4.33	4.33	10.17	6.00	7.83	6.00	6.00
	8	8.17	5.17	5.67	4.17	4.17	10.00	6.00	8.33	6.00	5.67
	10	7.83	4.50	5.67	4.83	3.83	9.33	5.33	8.83	5.33	5.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 56 – Taxa de reconhecimento com KNN na base AR com a técnica Fast Robust PCA com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	18.50	14.83	16.33	19.08	18.00	14.00	11.25	11.00	15.50	14.25
	2	18.50	14.83	16.33	19.08	18.00	14.00	11.25	11.00	15.50	14.25
	4	19.08	15.83	16.75	19.25	18.08	14.75	11.50	11.25	15.25	14.25
	6	20.25	16.33	17.08	19.17	18.08	15.75	11.25	11.50	15.25	13.50
	8	18.75	16.50	17.33	18.42	18.17	15.00	11.50	12.00	15.00	14.50
	10	19.67	17.08	17.08	17.92	17.08	15.25	12.75	12.75	14.75	14.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	23.17	20.00	21.33	28.17	26.17	13.83	9.67	11.33	10.00	9.83
	2	23.17	20.00	21.33	28.17	26.17	13.83	9.67	11.33	10.00	9.83
	4	24.00	21.17	22.00	28.83	26.33	14.17	10.50	11.50	9.67	9.83
	6	26.00	22.17	22.00	28.83	26.67	14.50	10.50	12.17	9.50	9.50
	8	24.50	22.67	22.67	27.50	26.67	13.00	10.33	12.00	9.33	9.67
	10	25.67	22.83	22.33	26.50	25.17	13.67	11.33	11.83	9.33	9.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 57 – Taxa de reconhecimento com KNN na base AR com a técnica Gappy PCA com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	49.17	43.58	45.42	38.00	38.17	50.50	42.50	44.25	38.25	38.25
	2	49.17	43.58	45.42	38.00	38.17	50.50	42.50	44.25	38.25	38.25
	4	48.25	43.75	45.33	37.58	37.50	49.00	42.00	44.00	36.25	37.25
	6	48.00	43.75	45.50	37.67	37.42	49.50	41.75	44.00	37.75	37.50
	8	46.75	42.92	45.42	36.42	36.92	48.25	41.75	44.00	36.50	38.25
	10	47.17	42.50	43.83	36.42	36.08	49.75	42.25	43.50	37.25	37.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	72.33	63.50	66.83	57.50	57.00	26.00	23.67	24.00	18.50	19.33
	2	72.33	63.50	66.83	57.50	57.00	26.00	23.67	24.00	18.50	19.33
	4	70.00	62.67	65.50	56.67	55.17	26.50	24.83	25.17	18.50	19.83
	6	69.50	62.17	65.83	55.67	54.00	26.50	25.33	25.17	19.67	20.83
	8	67.67	60.50	65.17	53.00	53.17	25.83	25.33	25.67	19.83	20.67
	10	67.17	58.83	63.00	52.33	51.17	27.17	26.17	24.67	20.50	21.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 58 – Taxa de reconhecimento com KNN na base AR com a técnica PCA com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	14.25	15.67	15.08	13.17	13.50	14.00	17.00	16.50	14.75	14.50
	2	14.25	15.67	15.08	13.17	13.50	14.00	17.00	16.50	14.75	14.50
	4	14.50	15.33	15.17	12.75	13.00	14.75	16.75	16.75	12.75	13.25
	6	14.08	15.92	15.17	13.00	13.17	14.00	17.50	16.25	13.50	13.75
	8	13.83	15.33	15.25	12.83	12.92	14.00	17.00	17.25	13.00	13.50
	10	13.08	15.00	14.75	12.92	14.00	14.00	16.25	16.75	13.75	14.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	18.33	19.83	19.00	18.50	18.67	10.17	11.50	11.17	7.83	8.33
	2	18.33	19.83	19.00	18.50	18.67	10.17	11.50	11.17	7.83	8.33
	4	19.67	20.00	19.83	18.33	18.50	9.33	10.67	10.50	7.17	7.50
	6	19.33	20.33	20.00	19.00	19.50	8.83	11.50	10.33	7.00	6.83
	8	19.17	19.83	20.17	19.00	19.17	8.50	10.83	10.33	6.67	6.67
	10	18.00	19.67	19.00	19.17	20.33	8.17	10.33	10.50	6.67	7.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 59 – Taxa de reconhecimento com KNN na base AR com a técnica Recursive PCA com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	53.25	48.00	50.17	42.17	41.25	56.50	50.50	52.00	42.75	42.50
	2	53.25	48.00	50.17	42.17	41.25	56.50	50.50	52.00	42.75	42.50
	4	51.58	47.58	48.67	41.00	40.50	55.75	50.00	50.25	40.75	41.25
	6	51.17	46.67	48.50	40.17	40.33	55.50	48.50	49.50	42.50	41.25
	8	50.00	45.25	47.92	39.67	39.33	55.25	47.50	48.50	42.25	42.25
	10	49.08	43.83	46.58	38.58	38.17	56.25	46.75	49.50	41.25	42.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	80.00	71.67	75.00	65.33	64.67	26.50	24.33	25.33	19.00	17.83
	2	80.00	71.67	75.00	65.33	64.67	26.50	24.33	25.33	19.00	17.83
	4	76.83	69.33	71.83	63.33	62.50	26.33	25.83	25.50	18.67	18.50
	6	76.83	68.00	72.00	61.83	61.33	25.50	25.33	25.00	18.50	19.33
	8	75.50	66.00	70.67	61.00	59.83	24.50	24.50	25.17	18.33	18.83
	10	73.17	63.33	68.17	58.17	57.17	25.00	24.33	25.00	19.00	19.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 60 – Taxa de reconhecimento com KNN na base AR com a técnica Asymmetrical PCA com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	39.17	40.50	39.50	37.33	37.92	39.50	40.50	40.00	39.00	39.75
	2	39.17	40.50	39.50	37.33	37.92	39.50	40.50	40.00	39.00	39.75
	4	38.75	39.58	39.00	37.08	37.42	41.25	40.00	40.75	38.00	38.00
	6	37.33	38.75	38.42	35.92	36.33	40.00	39.00	39.75	35.50	36.75
	8	36.83	37.67	37.83	35.50	36.00	39.75	38.00	39.00	35.00	36.75
	10	36.17	37.67	36.67	34.92	34.67	38.00	39.75	38.75	35.00	35.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	68.50	70.33	68.67	66.83	67.17	9.83	10.67	10.33	7.83	8.67
	2	68.50	70.33	68.67	66.83	67.17	9.83	10.67	10.33	7.83	8.67
	4	68.00	68.17	67.33	67.00	66.83	9.50	11.00	10.67	7.17	8.00
	6	65.33	66.67	65.83	64.67	64.50	9.33	10.83	11.00	7.17	8.17
	8	64.00	65.00	64.50	64.17	64.00	9.67	10.33	11.17	6.83	8.00
	10	62.67	65.33	63.00	62.83	61.50	9.67	10.00	10.33	7.00	7.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 61 – Taxa de reconhecimento da técnica SRC com *Fast Recursive* PCA com classificador KNN com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	84.58	83.33	83.67	80.58	80.08	92.50	90.50	91.50	90.25	90.00
	2	84.58	83.33	83.67	80.58	80.08	92.50	90.50	91.50	90.25	90.00
	4	82.33	80.42	80.92	77.17	76.42	90.50	89.00	89.50	87.75	86.75
	6	80.42	79.17	79.50	75.92	75.50	90.75	90.00	89.50	87.25	86.50
	8	78.33	77.33	77.83	73.83	73.42	89.75	88.25	89.25	85.50	85.00
	10	77.17	76.58	76.83	73.42	72.75	89.00	88.50	89.25	85.75	85.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	93.83	93.33	93.50	91.83	91.67	75.33	73.33	73.83	69.33	68.50
	2	93.83	93.33	93.50	91.83	91.67	75.33	73.33	73.83	69.33	68.50
	4	91.00	89.33	90.17	87.33	86.83	73.67	71.50	71.67	67.00	66.00
	6	89.50	88.50	88.17	85.00	85.17	71.33	69.83	70.83	66.83	65.83
	8	87.67	85.67	86.67	81.83	81.83	69.00	69.00	69.00	65.83	65.00
	10	85.67	84.67	85.00	81.67	81.67	68.67	68.50	68.67	65.17	63.83

Fonte: Jonas Mendonça Targino. 2019

KNN nível LL2

Tabela 62 – Taxa de reconhecimento da base ocluída com classificador KNN com nível de decomposição LL2

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	42.08	44.83	43.83	42.50	42.42	41.75	43.75	43.00	43.75	43.75
	2	42.08	44.83	43.83	42.50	42.42	41.75	43.75	43.00	43.75	43.75
	4	40.42	43.50	42.33	41.50	40.75	41.50	44.75	43.00	42.50	41.75
	6	39.83	42.42	42.17	40.25	40.08	40.75	43.25	43.00	41.50	41.00
	8	39.33	42.00	41.75	39.42	39.25	41.25	43.25	42.50	40.50	40.50
	10	38.67	41.00	40.75	38.92	39.00	41.00	42.00	41.50	40.50	39.50

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	72.17	76.17	73.00	74.17	74.00	12.00	13.50	14.67	10.83	10.83
	2	72.17	76.17	73.00	74.17	74.00	12.00	13.50	14.67	10.83	10.83
	4	69.83	74.67	71.33	72.83	71.33	11.00	12.33	13.33	10.17	10.17
	6	69.00	71.83	70.83	70.17	70.00	10.67	13.00	13.50	10.33	10.17
	8	67.83	71.33	69.00	68.00	67.50	10.83	12.67	14.50	10.83	11.00
	10	65.17	69.00	67.67	66.83	66.17	12.17	13.00	13.83	11.00	11.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 63 – Taxa de reconhecimento com KNN na base AR com a técnica *Fast Recursive PCA* com nível de decomposição LL2

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	56.33	56.67	56.42	51.25	51.00	63.00	61.75	61.50	55.75	55.50
	2	56.33	56.67	56.42	51.25	51.00	63.00	61.75	61.50	55.75	55.50
	4	55.25	55.42	55.33	50.92	50.08	61.75	61.00	61.75	55.75	54.50
	6	53.67	54.00	54.25	49.67	48.75	63.00	61.25	62.50	55.25	54.25
	8	52.92	53.50	53.00	48.33	47.92	61.25	61.25	60.50	53.75	53.00
	10	51.92	51.42	52.17	47.33	46.75	60.00	59.25	59.25	52.75	51.75

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	83.00	82.00	82.17	76.83	75.67	29.67	31.33	30.67	25.67	26.33
	2	83.00	82.00	82.17	76.83	75.67	29.67	31.33	30.67	25.67	26.33
	4	81.67	79.67	80.50	75.83	74.17	28.83	31.17	30.17	26.00	26.00
	6	79.33	77.67	78.83	73.33	71.83	28.00	30.33	29.67	26.00	25.67
	8	77.00	76.50	75.83	72.83	70.67	28.83	30.50	30.17	23.83	25.17
	10	76.50	73.17	74.50	70.17	68.33	27.33	29.67	29.83	24.50	25.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 64 – Taxa de reconhecimento com KNN na base AR com a técnica Fisherfaces com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	11.00	9.83	10.08	9.25	8.58	11.25	10.25	11.00	9.00	9.25
	2	11.00	9.83	10.08	9.25	8.58	11.25	10.25	11.00	9.00	9.25
	4	10.33	10.25	9.50	9.50	8.50	9.75	10.50	9.75	9.75	9.50
	6	9.92	10.42	10.00	8.58	8.42	9.75	11.00	10.75	9.00	9.50
	8	9.50	9.00	10.08	8.17	8.50	8.75	9.25	10.75	8.50	9.50
	10	9.25	8.83	10.00	7.50	8.08	9.00	9.00	11.00	8.00	9.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	8.83	7.33	7.50	7.33	6.83	13.17	12.33	12.67	11.17	10.33
	2	8.83	7.33	7.50	7.33	6.83	13.17	12.33	12.67	11.17	10.33
	4	8.17	7.50	7.17	7.83	7.00	12.50	13.00	11.83	11.17	10.00
	6	8.17	7.83	7.33	7.17	7.33	11.67	13.00	12.67	10.00	9.50
	8	7.67	6.00	7.17	7.17	7.17	11.33	12.00	13.00	9.17	9.83
	10	7.33	5.50	7.00	7.00	6.67	11.17	12.17	13.00	8.00	9.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 65 – Taxa de reconhecimento com KNN na base AR com a técnica *Fast Robust* PCA com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	21.17	20.00	20.17	22.50	22.08	17.50	14.00	14.50	18.25	17.75
	2	21.17	20.00	20.17	22.50	22.08	17.50	14.00	14.50	18.25	17.75
	4	21.00	20.42	21.00	22.50	21.83	17.75	15.25	16.75	18.25	17.00
	6	21.58	21.17	21.25	23.17	22.25	17.50	15.25	16.75	18.25	17.50
	8	22.00	20.92	20.92	22.33	22.25	19.00	16.00	15.50	17.75	16.75
	10	22.17	21.00	21.33	23.17	22.75	19.25	16.25	17.00	18.75	18.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	27.17	26.67	25.00	31.67	31.17	15.17	13.33	15.33	13.33	13.00
	2	27.17	26.67	25.00	31.67	31.17	15.17	13.33	15.33	13.33	13.00
	4	27.00	27.33	26.50	31.33	30.67	15.00	13.50	15.50	13.67	13.00
	6	28.17	28.67	27.00	32.67	32.33	15.00	13.67	15.50	13.67	12.17
	8	28.50	27.67	26.50	31.00	31.83	15.50	14.17	15.33	13.67	12.67
	10	28.50	27.83	27.00	32.17	32.00	15.83	14.17	15.67	14.17	13.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 66 – Taxa de reconhecimento com KNN na base AR com a técnica *Gappy* PCA com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	52.75	52.42	52.92	48.33	47.17	57.50	54.50	56.75	50.00	47.25
	2	52.75	52.42	52.92	48.33	47.17	57.50	54.50	56.75	50.00	47.25
	4	52.33	52.08	52.58	47.75	46.58	56.50	54.75	56.25	48.00	47.00
	6	50.67	51.33	51.25	47.17	46.33	56.75	55.00	56.50	50.00	48.75
	8	50.33	50.67	50.92	46.00	46.00	56.50	54.50	56.50	48.75	48.25
	10	49.42	49.75	50.33	44.67	44.42	56.25	54.00	55.00	48.50	47.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	76.50	74.83	75.00	70.83	69.67	29.00	30.00	30.83	25.83	24.67
	2	76.50	74.83	75.00	70.83	69.67	29.00	30.00	30.83	25.83	24.67
	4	74.83	73.17	74.33	69.50	67.83	29.83	31.00	30.83	26.00	25.33
	6	72.67	72.17	72.17	67.67	66.50	28.67	30.50	30.33	26.67	26.17
	8	71.17	70.50	70.50	65.67	66.17	29.50	30.83	31.33	26.33	25.83
	10	70.00	68.17	70.17	64.17	63.67	28.83	31.33	30.50	25.17	25.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 67 – Taxa de reconhecimento com KNN na base AR com a técnica PCA com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	14.08	15.08	14.92	14.25	14.25	14.00	14.75	14.25	14.75	15.00
	2	14.08	15.08	14.92	14.25	14.25	14.00	14.75	14.25	14.75	15.00
	4	14.08	15.58	14.75	13.75	14.00	14.75	15.75	14.50	14.00	14.25
	6	14.00	15.00	14.92	13.83	14.33	14.75	15.50	15.00	14.25	14.50
	8	14.00	15.67	14.42	13.83	14.25	14.50	16.50	15.00	15.00	14.75
	10	13.92	15.08	14.17	14.33	14.25	13.75	16.00	14.50	15.00	15.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	18.83	19.83	19.50	19.17	19.17	9.33	10.33	10.33	9.33	9.33
	2	18.83	19.83	19.50	19.17	19.17	9.33	10.33	10.33	9.33	9.33
	4	20.00	21.17	20.33	19.83	19.83	8.17	10.00	9.17	7.67	8.17
	6	19.83	20.33	20.83	19.83	20.00	8.17	9.67	9.00	7.83	8.67
	8	19.50	21.50	19.83	19.50	20.00	8.50	9.83	9.00	8.17	8.50
	10	19.17	20.67	18.83	19.67	19.33	8.67	9.50	9.50	9.00	9.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 68 – Taxa de reconhecimento com KNN na base AR com a técnica *Recursive PCA* com nível de decomposição LL2

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	56.42	56.58	56.50	51.33	51.00	63.25	61.50	61.75	55.75	55.50
	2	56.42	56.58	56.50	51.33	51.00	63.25	61.50	61.75	55.75	55.50
	4	55.17	55.42	55.33	51.00	50.00	61.50	61.00	61.75	56.00	54.25
	6	53.58	53.75	54.33	49.75	49.00	62.75	60.50	62.75	55.50	54.75
	8	53.00	53.42	53.17	48.42	47.58	61.75	61.25	61.25	54.00	52.25
	10	52.00	51.83	52.25	47.25	46.92	60.25	60.25	59.75	52.50	52.00

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	83.00	82.00	82.67	77.00	76.00	29.83	31.17	30.33	25.67	26.00
	2	83.00	82.00	82.67	77.00	76.00	29.83	31.17	30.33	25.67	26.00
	4	81.67	79.67	80.83	76.00	74.33	28.67	31.17	29.83	26.00	25.67
	6	79.33	77.67	79.17	73.67	72.17	27.83	29.83	29.50	25.83	25.83
	8	77.00	76.50	76.17	73.17	70.33	29.00	30.33	30.17	23.67	24.83
	10	76.50	73.50	74.83	70.50	68.67	27.50	30.17	29.67	24.00	25.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 69 – Taxa de reconhecimento com KNN na base AR com a técnica *Asymmetrical PCA* com nível de decomposição LL2

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	39.42	40.33	39.58	39.33	39.33	40.50	40.25	39.50	40.50	41.00
	2	39.42	40.33	39.58	39.33	39.33	40.50	40.25	39.50	40.50	41.00
	4	38.00	39.17	38.50	38.25	38.92	39.50	41.00	39.75	39.00	40.00
	6	36.92	38.92	37.75	37.67	37.75	40.25	40.50	41.25	38.75	38.50
	8	35.67	37.50	37.17	37.42	37.33	38.75	39.00	40.00	39.25	38.50
	10	35.75	37.58	37.08	36.67	36.75	39.25	38.75	40.00	39.00	39.25

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	69.00	70.83	68.00	70.17	69.83	9.83	9.83	11.17	8.50	8.83
	2	69.00	70.83	68.00	70.17	69.83	9.83	9.83	11.17	8.50	8.83
	4	67.67	68.67	67.33	69.00	69.67	8.33	9.67	9.67	7.50	8.17
	6	65.33	68.33	65.17	66.67	66.83	8.50	9.50	10.33	8.67	8.67
	8	62.50	65.67	63.67	66.33	66.33	8.83	9.33	10.67	8.50	8.33
	10	61.83	65.00	63.50	64.83	64.50	9.67	10.17	10.67	8.50	9.00

Fonte: Jonas Mendonça Targino. 2019

KNN nível LL1

Tabela 70 – Taxa de reconhecimento da técnica SRC com *Fast Recursive PCA* com classificador KNN com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	86.00	86.08	86.08	84.92	84.75	92.50	93.00	92.75	92.50	92.25
	2	86.00	86.08	86.08	84.92	84.75	92.50	93.00	92.75	92.50	92.25
	4	83.58	83.58	83.33	82.50	82.00	90.75	90.25	90.50	91.00	91.00
	6	81.67	82.75	82.33	80.42	80.33	90.50	90.75	90.75	89.75	89.75
	8	80.33	80.33	81.00	78.42	77.92	90.50	90.25	90.75	89.25	88.75
	10	79.83	77.83	79.08	77.33	76.75	90.75	89.25	90.00	88.75	88.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	94.83	94.83	94.83	94.00	93.67	77.17	77.33	77.33	75.83	75.83
	2	94.83	94.83	94.83	94.00	93.67	77.17	77.33	77.33	75.83	75.83
	4	92.17	91.83	91.50	90.83	91.00	75.00	75.33	75.17	74.17	73.00
	6	90.67	91.17	90.50	88.50	89.00	72.67	74.33	74.17	72.33	71.67
	8	89.33	88.83	89.50	87.33	86.50	71.33	71.83	72.50	69.50	69.33
	10	88.67	85.83	87.33	85.50	84.83	71.00	69.83	70.83	69.17	68.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 71 – Taxa de reconhecimento da base ocluída com classificador KNN com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	41.08	42.42	41.75	42.08	42.75	41.50	42.25	41.25	42.00	42.50
	2	41.08	42.42	41.75	42.08	42.75	41.50	42.25	41.25	42.00	42.50
	4	38.92	40.50	39.58	39.75	40.42	40.50	41.75	40.50	40.75	40.75
	6	37.92	39.58	39.25	38.83	39.58	39.25	41.75	40.50	41.00	41.25
	8	37.58	39.00	38.17	38.25	38.42	38.75	40.50	39.50	39.75	39.75
	10	36.92	38.83	38.00	37.58	38.17	38.25	40.75	39.00	39.25	39.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	70.33	71.17	70.67	71.67	73.00	11.83	13.67	12.83	12.50	12.50
	2	70.33	71.17	70.67	71.67	73.00	11.83	13.67	12.83	12.50	12.50
	4	67.17	69.17	67.83	68.33	69.83	10.67	11.83	11.33	11.17	11.00
	6	65.33	67.67	67.33	66.50	68.50	10.50	11.50	11.17	11.17	10.67
	8	63.67	65.83	64.33	65.00	65.17	11.50	12.17	12.00	11.50	11.67
	10	62.50	65.17	63.50	63.67	64.50	11.33	12.50	12.50	11.50	11.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 72 – Taxa de reconhecimento com KNN na base AR com a técnica *Fast Recursive PCA* com nível de decomposição LL1

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	56.67	57.58	57.08	55.58	55.25	64.75	65.00	64.50	62.25	62.25
	2	56.67	57.58	57.08	55.58	55.25	64.75	65.00	64.50	62.25	62.25
	4	55.33	55.92	55.83	54.92	55.00	63.25	64.00	63.25	62.25	62.50
	6	52.67	53.58	53.00	52.67	52.58	62.00	63.00	61.75	61.50	60.25
	8	52.33	53.42	53.08	52.08	52.08	62.25	63.00	62.50	61.00	60.50
	10	52.00	52.17	51.83	51.42	51.50	62.00	61.50	61.50	60.25	60.25

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	83.83	84.33	83.67	82.33	81.67	29.50	30.83	30.50	28.83	28.83
	2	83.83	84.33	83.67	82.33	81.67	29.50	30.83	30.50	28.83	28.83
	4	81.50	81.83	81.67	81.00	81.00	29.17	30.00	30.00	28.83	29.00
	6	77.33	79.00	78.00	77.67	77.50	28.00	28.17	28.00	27.67	27.67
	8	77.17	78.17	77.33	76.17	76.67	27.50	28.67	28.83	28.00	27.50
	10	76.50	76.67	76.00	75.17	75.33	27.50	27.67	27.67	27.67	27.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 73 – Taxa de reconhecimento com KNN na base AR com a técnica Fisherfaces com nível de decomposição LL1

K-vizinhos		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	10.75	12.42	11.92	11.83	12.42	10.50	12.00	11.75	11.75	12.50
	2	10.75	12.42	11.92	11.83	12.42	10.50	12.00	11.75	11.75	12.50
	4	10.00	12.25	11.33	11.17	11.75	10.00	11.75	11.00	11.50	11.75
	6	10.00	12.17	11.75	10.42	11.25	11.00	13.00	12.25	11.25	11.25
	8	9.67	11.50	11.08	10.67	10.67	10.50	11.75	12.25	11.75	10.25
	10	9.67	9.83	10.08	10.58	10.33	9.25	10.75	10.50	10.75	10.25

K-vizinhos		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	1	6.50	7.83	7.50	8.17	9.00	15.00	17.00	16.33	15.50	15.83
	2	6.50	7.83	7.50	8.17	9.00	15.00	17.00	16.33	15.50	15.83
	4	6.50	8.67	8.17	7.67	9.00	13.50	15.83	14.50	14.67	14.50
	6	7.50	9.17	9.00	7.50	8.50	12.50	15.17	14.50	13.33	14.00
	8	7.17	9.17	8.50	8.33	8.17	12.17	13.83	13.67	13.00	13.17
	10	7.33	7.33	8.00	8.67	8.50	12.00	12.33	12.17	12.50	12.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 74 – Taxa de reconhecimento com KNN na base AR com a técnica *Fast Robust PCA* com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	22.42	21.75	22.25	23.17	22.83	17.50	17.25	16.75	19.25	19.00
	2	22.42	21.75	22.25	23.17	22.83	17.50	17.25	16.75	19.25	19.00
	4	22.42	21.83	22.25	22.58	22.17	17.50	17.50	17.50	18.25	17.75
	6	23.00	22.17	23.17	23.83	23.50	19.50	18.00	18.75	19.75	18.50
	8	23.17	22.25	22.92	24.00	23.67	19.00	18.25	18.75	19.50	19.25
	10	23.67	22.33	23.25	23.75	23.75	20.25	18.00	19.50	20.75	20.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	27.00	26.17	26.83	30.33	29.83	17.83	17.33	17.67	16.00	15.83
	2	27.00	26.17	26.83	30.33	29.83	17.83	17.33	17.67	16.00	15.83
	4	27.17	26.17	27.00	28.67	28.67	17.67	17.50	17.50	16.50	15.67
	6	28.67	26.67	28.67	31.50	31.33	17.33	17.67	17.67	16.17	15.67
	8	29.50	26.83	28.17	31.17	31.33	16.83	17.67	17.67	16.83	16.00
	10	29.50	27.17	28.50	31.33	31.50	17.83	17.50	18.00	16.17	16.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 75 – Taxa de reconhecimento com KNN na base AR com a técnica *Gappy PCA* com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	53.25	54.08	53.50	53.08	52.75	62.25	61.50	61.00	59.50	58.50
	2	53.25	54.08	53.50	53.08	52.75	62.25	61.50	61.00	59.50	58.50
	4	52.08	52.83	52.67	52.17	52.50	61.00	60.25	60.50	58.75	58.25
	6	50.25	51.00	50.92	50.75	50.92	59.75	59.25	59.25	58.00	57.50
	8	49.67	50.67	50.17	50.17	50.50	60.75	58.75	59.25	59.00	58.25
	10	48.50	49.50	48.83	49.00	48.67	59.50	57.50	58.25	58.00	55.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	78.17	78.00	77.67	77.33	76.50	28.33	30.17	29.33	28.83	29.00
	2	78.17	78.00	77.67	77.33	76.50	28.33	30.17	29.33	28.83	29.00
	4	75.50	75.67	75.50	75.17	74.67	28.67	30.00	29.83	29.17	30.33
	6	72.67	72.00	72.83	73.17	72.83	27.83	30.00	29.00	28.33	29.00
	8	71.33	70.67	70.33	70.83	71.50	28.00	30.67	30.00	29.50	29.50
	10	69.50	69.83	69.50	69.83	69.33	27.50	29.17	28.17	28.17	28.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 76 – Taxa de reconhecimento com KNN na base AR com a técnica PCA com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	14.17	14.92	14.42	14.08	14.42	14.50	14.50	14.50	14.00	14.50
	2	14.17	14.92	14.42	14.08	14.42	14.50	14.50	14.50	14.00	14.50
	4	13.58	14.83	14.25	14.00	14.33	13.75	14.25	13.75	14.25	14.75
	6	13.67	14.58	14.08	14.17	14.58	13.75	14.75	14.00	14.25	15.25
	8	14.50	14.92	14.50	14.42	14.67	16.00	15.50	15.75	15.75	16.00
	10	14.83	14.25	14.58	14.17	14.42	15.75	14.75	15.00	15.00	15.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	19.50	19.83	19.33	19.17	19.50	8.83	10.00	9.50	9.00	9.33
	2	19.50	19.83	19.33	19.17	19.50	8.83	10.00	9.50	9.00	9.33
	4	20.00	21.50	20.33	20.17	20.17	7.17	8.17	8.17	7.83	8.50
	6	19.83	20.33	20.17	20.33	20.33	7.50	8.83	8.00	8.00	8.83
	8	21.00	20.50	20.17	20.00	20.33	8.00	9.33	8.83	8.83	9.00
	10	20.83	19.33	19.67	19.50	19.67	8.83	9.17	9.50	8.83	9.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 77 – Taxa de reconhecimento com KNN na base AR com a técnica *Recursive* PCA com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	56.67	57.50	56.92	55.75	55.17	64.75	64.75	64.25	63.00	62.25
	2	56.67	57.50	56.92	55.75	55.17	64.75	64.75	64.25	63.00	62.25
	4	55.25	55.83	55.92	54.75	54.92	63.25	63.75	63.50	61.75	62.25
	6	52.67	53.75	53.08	52.75	52.67	62.00	63.50	62.25	61.75	60.25
	8	52.17	53.25	52.92	52.00	52.42	61.75	62.75	62.50	60.75	61.25
	10	52.00	52.17	51.58	51.42	51.33	62.25	61.50	61.25	60.25	60.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	83.83	84.33	83.50	82.50	81.83	29.50	30.67	30.33	29.00	28.50
	2	83.83	84.33	83.50	82.50	81.83	29.50	30.67	30.33	29.00	28.50
	4	81.33	81.83	81.83	81.00	81.33	29.17	29.83	30.00	28.50	28.50
	6	77.33	79.17	78.17	77.83	77.67	28.00	28.33	28.00	27.67	27.67
	8	77.17	78.17	77.00	76.33	77.00	27.17	28.33	28.83	27.67	27.83
	10	76.33	76.67	75.67	75.50	75.50	27.67	27.67	27.50	27.33	27.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 78 – Taxa de reconhecimento com KNN na base AR com a técnica *Asymmetrical* PCA com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	37.00	39.42	38.83	38.92	39.50	38.25	39.50	39.50	40.25	41.25
	2	37.00	39.42	38.83	38.92	39.50	38.25	39.50	39.50	40.25	41.25
	4	35.92	37.75	37.75	37.33	37.92	38.25	39.25	38.75	39.50	40.00
	6	35.00	37.50	37.00	36.58	37.92	38.75	40.75	40.00	39.75	41.00
	8	34.92	36.33	35.92	35.83	36.25	38.00	39.25	39.25	39.00	39.50
	10	34.00	36.00	34.92	34.50	34.58	37.50	38.75	38.00	38.75	38.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	63.50	67.83	66.83	68.00	69.00	10.50	11.00	10.83	9.83	10.00
	2	63.50	67.83	66.83	68.00	69.00	10.50	11.00	10.83	9.83	10.00
	4	62.50	65.50	65.50	66.00	67.17	9.33	10.00	10.00	8.67	8.67
	6	61.33	65.17	64.50	64.50	66.83	8.67	9.83	9.50	8.67	9.00
	8	60.83	62.17	62.17	62.00	63.00	9.00	10.50	9.67	9.67	9.50
	10	59.00	61.83	60.50	59.17	59.67	9.00	10.17	9.33	9.83	9.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 79 – Taxa de reconhecimento da técnica SRC com *Fast Recursive* PCA com classificador KNN com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	86.75	86.75	86.75	86.50	86.33	93.00	93.00	93.00	92.75	92.75
	2	86.75	86.75	86.75	86.50	86.33	93.00	93.00	93.00	92.75	92.75
	4	84.17	84.25	84.08	84.17	84.17	91.50	91.75	91.50	91.50	92.00
	6	83.25	83.17	83.17	82.33	82.25	91.50	91.50	91.50	91.00	91.25
	8	80.58	81.42	81.00	80.33	80.33	90.00	90.50	90.50	90.25	90.75
	10	79.25	80.17	80.00	78.83	78.67	90.25	90.75	90.50	90.75	90.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	95.33	95.17	95.33	95.00	94.83	78.17	78.33	78.17	78.00	77.83
	2	95.33	95.17	95.33	95.00	94.83	78.17	78.33	78.17	78.00	77.83
	4	92.83	92.83	92.67	92.50	92.50	75.50	75.67	75.50	75.83	75.83
	6	92.00	91.50	91.50	90.33	90.17	74.50	74.83	74.83	74.33	74.33
	8	88.50	89.17	88.83	88.17	88.50	72.67	73.67	73.17	72.50	72.17
	10	87.17	88.00	87.67	87.00	86.33	71.33	72.33	72.33	70.67	71.00

Fonte: Jonas Mendonça Targino. 2019

E.1.3 Resultados com SVM

Tabela 80 – Taxa de reconhecimento da base ocluída com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Sigma	2E-03	58.67	60.50	59.50	54.08	54.25	65.25	64.00	65.75	55.50	56.00
	2E-04	58.83	59.17	58.50	54.25	53.67	66.25	66.75	65.25	59.00	58.50
	2E-05	58.25	58.92	57.50	53.17	51.67	66.50	65.00	64.75	59.00	57.75
	2E-06	57.25	61.08	58.83	54.42	54.25	66.00	69.50	66.75	63.00	63.25
	2E-07	54.00	56.75	55.67	52.08	51.50	62.75	65.25	62.50	58.00	57.00
	2E-08	54.58	56.33	55.67	51.58	51.67	63.25	64.75	62.50	58.00	57.00
	2E-09	50.25	52.83	52.50	49.25	49.25	60.00	62.00	60.75	56.25	56.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Sigma	2E-03	89.17	92.00	91.50	92.17	92.83	71.50	64.33	67.67	48.50	48.83
	2E-04	86.33	89.50	87.50	87.83	88.00	67.17	63.83	65.67	52.83	52.17
	2E-05	85.67	86.83	86.50	84.83	85.00	63.83	60.33	61.50	53.00	51.67
	2E-06	85.00	88.17	86.33	85.83	86.67	69.17	61.00	63.67	51.67	49.83
	2E-07	82.83	84.50	83.17	83.17	84.67	69.00	60.00	62.50	49.50	47.67
	2E-08	82.33	84.67	83.50	82.83	84.33	68.67	59.33	63.00	49.17	47.50
	2E-09	79.33	83.83	79.00	81.33	80.00	59.67	55.33	54.83	46.83	42.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 81 – Taxa de reconhecimento da técnica *Asymmetrical* PCA com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	54.83	56.92	55.42	50.00	50.92	60.00	61.00	61.00	52.25	52.00
	2E-04	54.00	55.42	54.83	49.67	48.58	60.75	61.50	62.00	55.75	53.25
	2E-05	53.92	55.08	53.00	48.58	48.42	61.25	62.25	61.75	55.75	54.75
	2E-06	52.25	57.08	54.67	50.00	50.08	61.00	65.00	63.00	57.75	56.50
	2E-07	49.67	53.08	51.58	48.83	48.42	57.75	59.00	58.75	54.25	53.75
	2E-08	50.17	53.25	52.17	48.33	48.33	57.25	59.00	59.25	53.50	53.50
	2E-09	47.00	50.17	49.00	45.58	45.58	56.50	57.25	55.25	51.75	50.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	88.50	90.50	89.67	91.00	91.50	69.50	61.83	66.50	48.67	48.50
	2E-04	84.83	87.83	85.83	86.33	88.33	64.50	59.83	63.50	50.67	52.00
	2E-05	84.50	86.67	85.67	84.67	85.33	62.67	59.33	62.00	50.17	51.50
	2E-06	83.33	86.67	85.67	85.17	85.67	66.50	59.50	62.50	50.67	49.17
	2E-07	81.17	83.17	81.83	81.33	84.00	66.67	57.67	60.50	48.33	46.17
	2E-08	81.33	83.33	81.83	81.33	84.17	67.00	57.67	60.17	47.67	47.17
	2E-09	77.33	82.67	78.17	79.67	79.67	56.33	53.67	54.00	46.33	43.33

Fonte: Jonas Mendonça Targino. 2019

Tabela 82 – Taxa de reconhecimento da técnica *Fast Recursive* PCA com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	70.42	67.33	68.92	61.92	62.67	84.00	78.25	81.25	73.75	71.75
	2E-04	68.67	67.08	66.92	63.67	63.83	84.00	81.00	83.50	79.25	79.00
	2E-05	68.25	64.75	65.33	62.42	62.42	83.00	79.75	82.50	79.50	78.75
	2E-06	67.33	67.00	65.25	63.08	62.08	82.00	82.00	82.00	79.75	80.25
	2E-07	63.25	60.50	60.50	59.83	59.08	77.50	75.75	75.75	72.75	72.50
	2E-08	63.50	60.83	60.75	60.17	59.17	78.25	75.75	75.75	73.00	72.25
	2E-09	59.00	56.75	57.33	57.50	58.50	76.25	73.00	74.25	72.75	70.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	88.50	90.50	89.67	91.00	91.50	69.50	61.83	66.50	48.67	48.50
	2E-04	84.83	87.83	85.83	86.33	88.33	64.50	59.83	63.50	50.67	52.00
	2E-05	84.50	86.67	85.67	84.67	85.33	62.67	59.33	62.00	50.17	51.50
	2E-06	83.33	86.67	85.67	85.17	85.67	66.50	59.50	62.50	50.67	49.17
	2E-07	81.17	83.17	81.83	81.33	84.00	66.67	57.67	60.50	48.33	46.17
	2E-08	81.33	83.33	81.83	81.33	84.17	67.00	57.67	60.17	47.67	47.17
	2E-09	77.33	82.67	78.17	79.67	79.67	56.33	53.67	54.00	46.33	43.33

Fonte: Jonas Mendonça Targino. 2019

Tabela 83 – Taxa de reconhecimento da técnica Fisherfaces com classificador SVM com nível de decomposição LL3

Gamma		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Gamma	2E-03	27.08	26.67	27.33	22.33	22.83	40.00	32.25	37.00	31.50	32.50
	2E-04	23.00	20.75	23.58	21.25	20.67	35.75	31.50	33.00	30.25	30.00
	2E-05	21.25	20.00	23.25	20.25	20.25	31.75	27.50	31.00	29.50	29.25
	2E-06	26.17	24.17	25.75	22.67	22.67	41.25	34.50	36.75	30.25	33.25
	2E-07	27.75	25.75	27.25	23.92	23.50	42.25	37.75	37.25	32.25	33.50
	2E-08	27.58	26.33	27.33	24.00	23.75	41.00	37.25	37.50	33.75	33.75
	2E-09	27.67	27.50	25.92	21.58	22.92	42.00	37.50	33.50	31.50	30.75

Gamma		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Gamma	2E-03	40.67	30.67	35.50	29.33	30.33	41.33	33.83	38.00	26.83	26.67
	2E-04	39.83	32.33	34.33	30.00	30.33	39.67	38.33	39.33	32.67	32.50
	2E-05	36.83	30.67	33.83	30.00	29.00	39.00	37.83	38.17	34.17	33.00
	2E-06	40.33	33.33	36.00	30.17	30.17	44.33	38.17	40.83	33.67	34.33
	2E-07	41.17	36.33	36.67	33.33	33.00	43.50	38.83	40.00	34.83	34.67
	2E-08	41.67	37.00	37.50	33.33	32.17	43.50	38.17	40.17	33.33	34.67
	2E-09	37.50	37.17	33.83	31.33	31.67	42.50	36.67	37.17	30.17	32.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 84 – Taxa de reconhecimento da técnica *Fast Robust* PCA com classificador SVM com nível de decomposição LL3

Gamma		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Gamma	2E-03	43.25	45.50	44.58	43.58	43.50	53.50	54.25	55.75	51.25	50.00
	2E-04	40.67	41.83	42.92	40.58	40.75	51.75	52.00	52.75	52.00	51.00
	2E-05	39.58	40.17	41.50	38.58	39.25	48.25	50.75	52.25	49.75	49.75
	2E-06	41.42	43.75	42.42	42.75	41.83	54.75	54.75	55.50	53.00	50.75
	2E-07	41.17	44.33	42.33	41.58	41.17	52.00	52.00	52.75	52.00	49.25
	2E-08	41.58	44.42	42.00	42.00	41.58	51.25	52.00	52.50	51.50	49.75
	2E-09	39.58	41.83	39.92	39.75	38.92	52.25	51.50	49.75	48.25	47.00

Gamma		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Gamma	2E-03	80.83	83.50	82.50	83.50	84.67	53.00	48.00	50.33	39.50	40.33
	2E-04	75.00	76.00	74.50	74.50	76.00	49.83	45.67	46.00	40.00	41.83
	2E-05	71.00	73.00	71.83	71.67	71.50	49.00	44.00	44.17	39.17	41.83
	2E-06	74.83	76.67	75.17	74.17	75.50	48.67	46.00	46.67	41.17	39.83
	2E-07	71.50	74.33	73.17	73.17	76.00	47.00	45.00	45.33	40.67	39.83
	2E-08	72.33	74.50	73.17	73.00	75.33	47.00	45.33	45.83	40.50	40.17
	2E-09	71.33	71.67	70.67	72.33	74.17	43.17	42.33	40.83	38.50	35.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 85 – Taxa de reconhecimento da técnica *Gappy* PCA com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	66.42	61.75	63.75	57.50	57.50	82.00	73.50	75.50	70.75	68.25
	2E-04	64.33	61.67	62.42	58.92	59.33	81.00	77.50	78.00	73.75	73.50
	2E-05	62.75	60.75	60.58	57.33	57.25	80.25	76.50	78.00	74.25	73.75
	2E-06	61.83	60.83	60.83	58.50	57.92	78.50	76.00	77.75	75.25	74.75
	2E-07	57.75	55.50	56.50	55.08	53.92	73.50	71.25	71.75	70.50	67.50
	2E-08	57.75	55.33	56.75	55.33	54.33	73.50	70.00	71.00	69.75	67.50
	2E-09	54.75	53.33	53.25	53.08	53.92	72.75	70.50	70.75	70.50	67.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	80.83	83.50	82.50	83.50	84.67	53.00	48.00	50.33	39.50	40.33
	2E-04	75.00	76.00	74.50	74.50	76.00	49.83	45.67	46.00	40.00	41.83
	2E-05	71.00	73.00	71.83	71.67	71.50	49.00	44.00	44.17	39.17	41.83
	2E-06	74.83	76.67	75.17	74.17	75.50	48.67	46.00	46.67	41.17	39.83
	2E-07	71.50	74.33	73.17	73.17	76.00	47.00	45.00	45.33	40.67	39.83
	2E-08	72.33	74.50	73.17	73.00	75.33	47.00	45.33	45.83	40.50	40.17
	2E-09	71.33	71.67	70.67	72.33	74.17	43.17	42.33	40.83	38.50	35.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 86 – Taxa de reconhecimento da técnica PCA com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	29.83	29.67	29.92	24.33	24.08	39.75	35.75	39.25	33.00	29.50
	2E-04	28.25	27.83	29.00	23.92	22.67	42.00	39.50	40.25	34.25	31.75
	2E-05	27.92	27.25	28.17	23.33	23.75	42.75	38.50	41.50	35.75	34.75
	2E-06	28.25	28.92	29.17	24.42	23.17	45.25	42.75	43.00	37.75	35.50
	2E-07	27.25	28.25	28.17	25.42	23.92	41.00	37.00	38.25	33.75	31.75
	2E-08	27.50	27.92	27.83	24.92	23.83	41.50	36.75	38.25	34.25	32.25
	2E-09	24.83	25.58	25.83	23.08	21.92	39.25	36.00	36.50	30.00	29.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	55.83	54.50	54.33	48.33	48.50	55.00	50.00	53.17	39.17	38.83
	2E-04	50.67	50.33	49.33	45.17	45.50	49.17	46.83	48.50	40.00	40.83
	2E-05	50.17	47.33	45.83	42.67	43.50	47.50	44.83	46.00	38.67	40.17
	2E-06	53.17	49.17	50.83	44.33	44.83	50.67	44.17	46.83	39.67	37.50
	2E-07	50.67	47.50	49.17	42.83	43.17	51.17	43.83	47.17	40.17	39.17
	2E-08	49.67	49.00	48.50	43.17	43.17	51.17	44.33	47.33	40.00	38.17
	2E-09	46.33	45.33	45.83	40.33	40.50	42.83	41.50	42.83	38.33	37.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 87 – Taxa de reconhecimento da técnica *Recursive PCA* com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	70.33	67.25	69.00	62.33	62.58	84.25	78.25	81.00	73.50	71.75
	2E-04	68.58	66.92	67.00	63.58	63.92	84.00	80.75	83.50	79.25	78.75
	2E-05	68.42	64.83	65.42	62.42	62.42	83.00	79.25	82.25	79.75	78.50
	2E-06	67.25	66.83	65.25	63.08	62.50	82.00	81.75	82.25	80.00	80.50
	2E-07	63.25	60.50	60.50	60.08	59.08	77.50	75.75	75.50	72.50	72.25
	2E-08	63.50	60.92	60.92	60.33	59.25	78.25	75.75	75.75	72.75	72.00
	2E-09	58.83	56.75	57.33	57.50	58.50	76.50	73.25	74.25	73.25	70.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	70.33	67.25	69.00	62.33	62.58	84.25	78.25	81.00	73.50	71.75
	2E-04	68.58	66.92	67.00	63.58	63.92	84.00	80.75	83.50	79.25	78.75
	2E-05	68.42	64.83	65.42	62.42	62.42	83.00	79.25	82.25	79.75	78.50
	2E-06	67.25	66.83	65.25	63.08	62.50	82.00	81.75	82.25	80.00	80.50
	2E-07	63.25	60.50	60.50	60.08	59.08	77.50	75.75	75.50	72.50	72.25
	2E-08	63.50	60.92	60.92	60.33	59.25	78.25	75.75	75.75	72.75	72.00
	2E-09	58.83	56.75	57.33	57.50	58.50	76.50	73.25	74.25	73.25	70.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 88 – Taxa de reconhecimento da técnica SRC com *Fast Recursive PCA* com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	89.25	89.00	89.00	88.58	88.25	94.00	93.25	93.50	94.00	93.75
	2E-04	88.83	88.83	89.08	88.50	88.25	94.00	93.25	94.25	94.00	93.75
	2E-05	88.67	88.92	89.08	88.50	88.25	94.00	93.25	94.00	94.25	93.75
	2E-06	88.08	87.75	87.67	87.25	87.42	93.25	93.25	93.25	93.25	93.50
	2E-07	87.33	87.42	86.83	86.25	85.83	93.25	93.00	93.00	92.50	92.50
	2E-08	87.25	87.17	86.83	86.25	85.92	93.25	93.00	93.25	92.50	92.50
	2E-09	85.58	85.67	86.08	85.33	85.42	93.00	92.75	93.50	92.00	92.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	95.83	95.50	95.83	95.33	95.33	83.83	83.83	83.50	82.67	82.83
	2E-04	95.67	95.50	95.67	95.67	95.83	83.17	84.00	83.33	83.00	82.67
	2E-05	95.83	95.33	95.83	95.83	95.83	83.00	84.00	83.17	82.17	82.50
	2E-06	95.50	95.17	95.50	95.17	95.17	81.33	82.00	81.50	81.67	81.50
	2E-07	95.33	95.17	95.33	94.50	95.00	80.67	80.50	80.00	79.17	78.83
	2E-08	95.33	95.17	95.17	94.33	94.83	81.00	80.33	80.17	78.83	78.50
	2E-09	94.50	94.00	94.50	94.00	95.00	78.17	78.67	78.50	78.17	78.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 89 – Taxa de reconhecimento da base ocluída com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Sigma	2E-03	54.75	58.33	57.25	54.42	54.00	57.25	62.25	59.75	53.50	52.75
	2E-04	63.17	66.50	66.25	61.25	61.33	69.25	72.50	72.25	67.25	67.00
	2E-05	63.50	65.42	65.67	62.42	61.67	71.50	72.50	73.00	70.75	68.75
	2E-06	62.83	65.17	65.08	61.83	61.42	70.00	72.50	72.00	69.00	68.50
	2E-07	57.92	62.17	60.75	58.58	58.17	65.50	68.50	69.00	64.00	64.75
	2E-08	57.75	61.25	60.17	58.50	57.92	65.50	67.75	69.00	63.25	65.00
	2E-09	57.08	60.75	59.33	58.50	58.17	65.00	67.00	67.25	63.25	64.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Sigma	2E-03	92.67	93.50	93.50	92.67	93.17	71.33	67.50	71.83	57.67	55.17
	2E-04	91.67	93.00	92.50	92.33	92.67	77.33	77.33	78.67	69.67	68.50
	2E-05	89.17	91.33	91.67	89.83	90.00	75.50	74.67	76.33	68.17	67.33
	2E-06	88.67	90.50	91.00	89.33	89.67	75.83	74.83	76.83	68.17	66.33
	2E-07	87.67	89.00	88.83	88.00	87.50	77.33	75.00	77.33	68.50	65.67
	2E-08	87.17	88.67	88.50	87.33	87.00	77.17	74.67	77.17	68.00	65.83
	2E-09	87.00	89.00	88.33	87.17	88.00	76.00	73.83	76.83	69.83	67.33

Fonte: Jonas Mendonça Targino. 2019

Tabela 90 – Taxa de reconhecimento da técnica APCA com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Gamma	2E-03	51.08	54.83	53.67	49.08	50.08	51.75	55.75	54.25	48.75	48.00
	2E-04	57.83	61.42	60.67	56.33	56.92	64.00	67.50	67.25	62.50	62.25
	2E-05	57.75	61.33	60.08	57.50	56.42	65.50	67.25	68.25	63.50	63.50
	2E-06	58.25	61.08	60.42	57.58	56.58	66.00	67.75	68.75	64.50	64.00
	2E-07	52.92	56.83	56.17	54.25	54.00	60.50	63.75	64.00	59.00	59.25
	2E-08	53.08	56.42	55.58	54.17	53.50	60.00	63.25	63.50	59.50	59.00
	2E-09	52.25	56.67	54.67	54.92	53.92	58.75	63.25	61.50	58.75	59.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
Gamma	2E-03	90.50	91.33	91.00	91.83	92.33	68.33	65.50	69.67	54.00	53.00
	2E-04	88.83	91.17	90.00	90.17	91.17	75.50	76.33	76.67	67.50	68.17
	2E-05	87.50	89.33	88.50	88.50	89.00	73.33	72.67	73.17	66.33	64.83
	2E-06	87.33	89.17	88.50	88.50	88.17	73.17	71.83	73.33	65.67	65.17
	2E-07	84.67	88.00	86.83	86.50	86.83	76.00	74.00	76.67	68.17	67.83
	2E-08	84.17	87.50	86.50	85.83	85.83	75.33	74.00	76.50	68.00	67.00
	2E-09	83.33	87.83	85.83	85.17	87.17	75.50	72.67	75.67	68.33	66.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 91 – Taxa de reconhecimento da técnica *Fast Recursive PCA* com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	69.42	70.67	70.25	67.17	66.17	82.75	79.00	81.50	77.25	75.50
	2E-04	76.33	75.58	75.25	73.33	73.00	87.50	87.25	87.25	87.00	86.50
	2E-05	75.00	74.08	75.00	72.50	72.17	88.25	87.75	87.75	87.50	86.25
	2E-06	73.75	74.33	74.92	71.75	70.83	87.25	87.25	87.50	86.50	86.25
	2E-07	70.17	70.83	70.58	68.83	68.75	81.50	82.50	82.50	80.50	81.50
	2E-08	69.75	69.83	70.08	68.58	68.42	81.00	80.50	81.50	79.75	80.25
	2E-09	69.92	69.17	69.08	68.17	68.50	81.00	80.50	80.50	80.00	80.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	92.67	90.67	91.83	92.33	92.33	76.50	72.83	77.00	69.50	67.33
	2E-04	91.00	90.50	90.17	91.50	91.50	81.33	79.00	80.50	76.33	75.33
	2E-05	89.50	90.00	89.83	89.67	89.17	80.50	79.33	80.67	76.17	75.17
	2E-06	89.00	89.00	89.17	88.50	89.00	80.50	77.83	80.67	76.50	75.17
	2E-07	87.67	87.67	88.00	88.17	88.00	77.83	76.67	77.83	74.33	73.33
	2E-08	87.33	87.00	87.67	87.50	87.83	77.00	75.33	76.67	73.83	73.17
	2E-09	87.00	86.50	87.17	87.67	87.33	77.00	75.17	76.67	74.17	72.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 92 – Taxa de reconhecimento da técnica Fisherfaces com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	27.08	26.67	27.33	22.33	22.83	40.00	32.25	37.00	31.50	32.50
	2E-04	23.00	20.75	23.58	21.25	20.67	35.75	31.50	33.00	30.25	30.00
	2E-05	21.25	20.00	23.25	20.25	20.25	31.75	27.50	31.00	29.50	29.25
	2E-06	26.17	24.17	25.75	22.67	22.67	41.25	34.50	36.75	30.25	33.25
	2E-07	27.75	25.75	27.25	23.92	23.50	42.25	37.75	37.25	32.25	33.50
	2E-08	27.58	26.33	27.33	24.00	23.75	41.00	37.25	37.50	33.75	33.75
	2E-09	27.67	27.50	25.92	21.58	22.92	42.00	37.50	33.50	31.50	30.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	40.67	30.67	35.50	29.33	30.33	41.33	33.83	38.00	26.83	26.67
	2E-04	39.83	32.33	34.33	30.00	30.33	39.67	38.33	39.33	32.67	32.50
	2E-05	36.83	30.67	33.83	30.00	29.00	39.00	37.83	38.17	34.17	33.00
	2E-06	40.33	33.33	36.00	30.17	30.17	44.33	38.17	40.83	33.67	34.33
	2E-07	41.17	36.33	36.67	33.33	33.00	43.50	38.83	40.00	34.83	34.67
	2E-08	41.67	37.00	37.50	33.33	32.17	43.50	38.17	40.17	33.33	34.67
	2E-09	37.50	37.17	33.83	31.33	31.67	42.50	36.67	37.17	30.17	32.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 93 – Taxa de reconhecimento da técnica *Fast Robust* PCA com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	38.08	42.67	41.33	40.25	41.33	45.00	48.25	46.50	46.50	46.75
	2E-04	43.58	46.42	45.42	45.17	45.83	54.75	57.50	56.25	55.25	55.50
	2E-05	42.00	45.67	43.33	44.25	44.50	55.00	56.00	54.25	55.75	55.00
	2E-06	41.92	44.08	43.42	43.58	43.92	55.25	55.00	54.75	55.00	54.75
	2E-07	44.08	45.25	44.25	44.67	45.17	53.75	56.00	54.50	54.25	55.25
	2E-08	43.58	44.42	43.67	44.33	45.17	52.75	55.50	54.25	53.50	54.50
	2E-09	42.58	44.75	43.42	43.92	44.00	54.00	53.00	52.25	53.50	53.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	79.83	82.67	80.83	84.50	85.33	50.83	49.50	52.67	44.17	41.83
	2E-04	77.83	79.50	77.33	80.00	81.00	55.33	56.83	56.83	50.83	49.83
	2E-05	75.33	76.17	75.17	74.17	75.33	54.50	53.67	54.50	50.50	49.50
	2E-06	73.50	75.83	74.67	74.17	74.50	54.83	53.50	55.17	51.00	49.33
	2E-07	74.00	75.00	73.33	75.17	76.17	52.00	52.33	53.83	48.83	48.83
	2E-08	73.00	74.17	73.17	74.17	74.67	51.50	51.83	52.83	48.67	48.67
	2E-09	73.33	74.00	73.50	73.67	74.50	50.67	51.17	53.67	49.83	47.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 94 – Taxa de reconhecimento da técnica *Gappy* PCA com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	66.50	66.08	66.00	63.25	61.58	77.50	75.50	77.00	73.00	72.00
	2E-04	70.75	70.17	70.50	69.67	69.58	84.00	83.25	83.50	83.50	82.75
	2E-05	69.83	69.75	69.75	67.50	67.00	84.50	84.25	84.50	83.50	82.75
	2E-06	69.58	69.00	69.00	67.17	66.33	83.75	83.00	83.75	83.00	82.50
	2E-07	64.50	63.75	64.17	63.83	63.83	78.50	79.25	79.50	77.75	78.50
	2E-08	63.67	63.50	63.67	63.25	63.33	76.75	77.50	78.25	76.25	76.50
	2E-09	64.00	63.17	63.58	62.92	63.42	77.00	77.25	76.75	75.25	76.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	89.00	88.00	88.50	89.33	89.00	68.83	63.83	67.83	61.00	58.83
	2E-04	88.67	87.17	88.17	89.33	89.33	73.67	71.83	73.67	71.17	69.00
	2E-05	86.00	85.00	84.67	86.67	86.00	74.67	71.67	73.17	68.83	67.50
	2E-06	86.00	84.67	84.33	85.67	85.67	73.50	70.83	73.17	68.83	66.83
	2E-07	84.00	83.17	83.33	84.00	83.83	70.50	68.83	70.67	67.00	65.83
	2E-08	83.83	82.50	82.67	83.50	83.33	69.83	68.50	69.00	66.33	64.83
	2E-09	83.17	81.83	82.00	83.00	81.33	69.50	67.33	67.67	65.83	63.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 95 – Taxa de reconhecimento da técnica PCA com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	28.00	29.75	29.75	25.58	26.33	38.25	37.00	39.75	31.25	31.25
	2E-04	32.50	33.75	33.42	30.42	30.42	48.50	49.75	50.75	44.50	43.75
	2E-05	32.17	32.83	32.33	29.75	29.50	49.75	50.00	50.25	45.25	45.25
	2E-06	31.83	33.50	32.00	29.17	30.00	50.25	49.50	51.25	47.00	46.75
	2E-07	30.50	32.67	32.33	29.67	29.67	45.00	48.75	47.00	42.25	41.75
	2E-08	30.33	31.67	32.25	29.58	29.67	45.75	48.00	47.75	41.50	40.75
	2E-09	29.33	31.33	32.00	29.42	28.92	44.75	47.25	45.00	41.50	40.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	58.67	57.83	59.17	55.67	54.50	54.83	52.33	55.33	45.33	43.00
	2E-04	57.00	56.33	56.83	54.33	53.33	55.67	56.67	57.00	52.83	51.83
	2E-05	54.17	54.67	54.50	52.33	51.83	53.50	53.67	54.67	49.50	49.83
	2E-06	54.83	54.67	55.00	52.00	51.83	52.83	52.83	53.50	49.00	48.67
	2E-07	55.83	54.17	55.83	51.67	51.83	57.83	55.50	58.50	52.83	50.83
	2E-08	54.67	52.67	54.50	51.00	51.17	57.50	55.50	57.50	52.67	51.00
	2E-09	54.50	52.33	53.17	49.67	51.17	57.17	54.83	59.17	52.67	51.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 96 – Taxa de reconhecimento da técnica *Recursive* PCA com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	69.42	70.75	70.08	67.17	66.33	82.75	79.00	81.50	77.50	75.50
	2E-04	76.25	75.58	75.42	73.42	73.08	87.50	87.25	87.25	87.25	86.50
	2E-05	74.92	74.17	75.08	72.50	72.25	88.00	87.75	88.00	87.25	86.50
	2E-06	73.75	74.25	74.75	71.83	71.00	87.25	87.50	87.50	86.50	86.50
	2E-07	70.33	70.83	70.58	68.83	68.92	81.75	82.25	82.25	80.50	81.50
	2E-08	69.83	69.92	70.00	68.50	68.58	80.75	80.50	80.75	79.50	80.00
	2E-09	70.00	69.17	69.17	68.08	68.50	80.75	80.25	80.50	80.00	80.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	92.67	90.67	91.83	92.50	92.17	76.67	73.00	77.17	69.83	67.33
	2E-04	91.00	90.50	90.17	91.50	91.67	81.33	79.00	80.50	76.33	75.50
	2E-05	89.50	90.00	89.83	89.83	89.33	80.67	79.33	80.67	76.33	75.00
	2E-06	89.00	89.00	89.17	88.50	89.17	80.50	78.00	80.67	76.50	75.33
	2E-07	87.67	87.67	88.00	88.17	88.17	77.83	76.33	77.83	74.50	73.33
	2E-08	87.33	87.00	87.67	87.50	87.67	77.00	75.00	77.00	74.00	73.33
	2E-09	87.17	86.50	87.00	87.67	87.33	77.17	75.17	76.67	74.33	72.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 97 – Taxa de reconhecimento da técnica SRC com *Fast Recursive PCA* com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	89.33	89.17	89.17	89.08	88.83	94.75	95.00	94.75	94.75	94.50
	2E-04	89.67	89.92	90.08	89.33	89.33	94.50	94.50	94.50	94.50	94.50
	2E-05	89.50	89.25	89.42	89.17	89.17	94.75	94.25	94.50	94.50	94.25
	2E-06	89.50	89.25	89.25	89.08	89.08	94.00	94.00	94.00	94.25	94.00
	2E-07	88.50	88.08	88.50	87.92	87.75	93.50	93.50	93.75	93.75	93.75
	2E-08	88.33	87.92	88.25	87.67	87.58	93.25	93.25	93.75	93.50	93.50
	2E-09	88.17	88.25	88.42	87.83	87.75	93.50	93.50	93.50	93.75	93.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	96.33	96.00	96.00	96.33	96.33	84.50	84.17	84.17	84.00	83.50
	2E-04	96.00	96.00	96.00	96.17	96.00	85.17	85.00	84.67	84.50	84.50
	2E-05	96.17	95.67	95.83	96.00	96.00	84.50	84.83	84.50	83.83	83.67
	2E-06	95.83	95.67	95.83	96.00	95.83	83.83	84.67	84.67	83.50	83.33
	2E-07	95.67	95.83	95.83	96.00	96.00	82.50	82.33	83.33	82.33	81.67
	2E-08	95.50	95.67	95.50	95.83	95.83	82.50	81.83	82.83	82.17	81.33
	2E-09	95.83	95.50	95.50	95.83	95.50	82.00	82.00	82.67	82.00	81.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 98 – Taxa de reconhecimento da base ocluída com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	28.67	29.33	29.17	27.17	26.67	22.75	22.25	22.50	19.25	19.25
	2E-04	59.42	61.33	60.25	59.00	59.17	67.00	68.50	68.25	65.50	65.75
	2E-05	62.83	64.58	63.17	62.17	62.42	71.00	73.00	72.50	70.00	71.25
	2E-06	62.58	64.33	63.58	62.08	62.17	72.50	75.25	74.00	72.50	72.25
	2E-07	63.08	64.75	64.25	62.67	63.17	72.50	74.00	73.25	71.00	71.50
	2E-08	57.08	59.25	58.50	57.42	57.50	65.00	66.25	66.00	64.00	64.75
	2E-09	57.25	59.67	58.00	57.33	57.67	64.50	66.75	65.75	64.25	65.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	81.83	81.50	82.00	82.50	82.33	48.17	46.67	47.50	40.50	38.67
	2E-04	93.00	93.17	93.00	93.33	93.67	78.67	78.67	78.50	76.00	74.67
	2E-05	89.50	91.00	90.50	90.50	91.17	79.33	79.33	79.33	76.50	76.00
	2E-06	88.83	89.50	89.17	89.83	89.83	79.00	78.50	78.83	74.67	74.83
	2E-07	89.67	90.33	90.67	90.50	90.83	77.83	78.33	78.17	76.33	76.17
	2E-08	86.17	88.83	88.00	88.00	88.17	77.50	78.17	78.00	75.83	75.83
	2E-09	86.50	88.83	88.00	87.33	88.17	77.67	77.50	77.83	76.50	75.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 99 – Taxa de reconhecimento da técnica *Asymmetrical* PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	26.17	26.42	26.33	24.42	24.00	19.00	18.00	19.00	17.00	16.25
	2E-04	54.58	56.67	56.33	54.67	55.50	61.50	64.00	63.25	61.25	61.25
	2E-05	57.42	59.67	58.25	58.58	58.33	65.50	67.50	66.75	66.00	65.75
	2E-06	57.67	59.67	58.50	57.92	58.33	65.50	68.25	68.00	66.00	66.25
	2E-07	56.75	58.92	58.33	57.58	58.42	66.00	68.25	67.50	65.50	65.75
	2E-08	52.00	54.08	53.33	52.58	52.92	58.75	62.75	60.75	59.75	60.25
	2E-09	52.08	54.33	52.92	52.25	53.00	59.00	62.50	60.75	60.50	60.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	81.50	81.67	82.00	83.00	82.83	46.17	43.83	44.83	39.33	37.17
	2E-04	90.83	91.50	91.67	91.33	92.33	76.83	77.17	77.00	75.00	74.00
	2E-05	88.33	89.33	89.00	88.67	88.83	76.50	75.83	76.17	74.50	74.17
	2E-06	87.33	88.17	88.17	87.67	88.17	75.33	76.33	76.17	73.17	73.83
	2E-07	87.83	89.00	89.00	89.00	88.83	76.67	76.33	76.67	74.83	74.33
	2E-08	85.00	85.83	85.67	85.50	86.00	77.50	77.67	77.33	75.67	75.50
	2E-09	85.00	85.83	85.33	85.67	86.33	76.83	77.17	77.83	76.00	75.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 100 – Taxa de reconhecimento da técnica *Fast Recursive* PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	54.92	54.92	54.33	53.83	52.00	52.25	49.00	51.00	48.25	47.50
	2E-04	76.33	77.00	77.17	75.92	76.25	87.00	87.50	87.75	86.50	86.50
	2E-05	76.33	77.08	76.58	75.33	75.67	88.50	88.75	88.50	88.75	88.75
	2E-06	76.00	76.92	76.67	75.42	75.50	88.25	88.75	88.75	89.00	88.75
	2E-07	74.58	75.83	75.42	75.42	75.25	88.00	88.75	88.25	88.00	88.25
	2E-08	69.17	70.83	70.42	70.25	70.42	82.00	82.25	82.25	82.00	81.50
	2E-09	69.17	70.67	70.58	70.08	70.33	81.75	82.25	82.25	81.50	81.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	86.67	85.67	86.33	86.67	86.83	61.83	61.33	61.67	57.83	55.50
	2E-04	91.83	92.67	92.50	93.00	93.17	83.17	83.00	83.17	81.33	81.33
	2E-05	91.50	91.17	91.33	91.50	91.67	83.50	83.83	84.00	81.67	81.67
	2E-06	90.33	89.83	90.00	90.50	90.83	83.33	83.33	83.50	82.17	81.67
	2E-07	91.17	91.00	91.17	91.00	91.00	81.50	81.83	82.50	80.50	80.50
	2E-08	87.00	88.67	88.00	87.67	88.83	79.17	79.17	79.17	77.33	77.33
	2E-09	86.83	88.33	88.00	87.33	88.83	79.17	79.17	78.83	78.17	77.33

Fonte: Jonas Mendonça Targino. 2019

Tabela 101 – Taxa de reconhecimento da técnica Fisherfaces com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
	2E-04	30.67	32.00	31.75	31.58	32.67	45.25	46.75	46.25	44.25	44.25
	2E-05	27.25	27.75	27.75	27.33	27.92	39.00	40.25	39.50	39.00	39.25
	2E-06	25.75	26.08	26.00	24.83	25.67	37.75	38.50	38.25	37.25	37.50
	2E-07	28.00	28.42	28.33	27.75	28.00	41.25	43.75	42.75	42.25	42.50
	2E-08	30.58	32.17	31.08	31.25	32.67	45.25	46.00	45.25	45.25	45.25
	2E-09	30.33	32.33	31.42	31.25	31.92	45.00	45.75	45.25	44.75	45.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	5.00	3.50	4.50	3.33	3.17	6.83	5.17	6.33	4.50	4.33
	2E-04	44.17	44.00	44.17	44.33	44.33	46.17	46.17	45.67	44.50	44.17
	2E-05	43.00	41.83	42.50	43.17	43.33	46.50	47.33	47.33	45.83	46.00
	2E-06	41.33	40.33	40.50	40.50	40.17	46.83	47.17	47.00	46.67	45.50
	2E-07	42.83	42.17	42.50	42.17	42.67	46.67	47.17	47.17	46.17	46.17
	2E-08	42.17	43.50	43.17	43.17	43.33	49.33	51.33	50.17	49.50	50.00
	2E-09	42.17	43.33	42.83	43.17	42.83	49.67	50.33	50.33	49.17	50.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 102 – Taxa de reconhecimento da técnica *Fast Robust* PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	14.58	14.50	14.92	13.25	12.92	9.50	10.50	10.25	9.50	9.25
	2E-04	41.33	43.50	42.92	42.50	43.25	53.75	56.75	55.00	55.25	55.25
	2E-05	40.75	43.17	42.42	42.25	43.17	54.25	55.50	55.25	56.00	56.25
	2E-06	41.50	43.08	42.67	42.33	42.75	53.25	55.00	53.75	55.50	56.50
	2E-07	43.25	45.17	44.75	44.58	45.25	55.75	55.50	56.00	56.00	56.75
	2E-08	40.67	43.00	42.25	42.33	43.08	51.25	52.25	51.25	52.50	54.00
	2E-09	40.83	42.67	42.42	42.50	43.08	50.75	52.25	51.00	52.50	53.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	49.17	50.17	49.67	51.00	51.67	27.50	27.50	27.33	23.33	21.83
	2E-04	78.67	81.17	80.00	80.17	81.33	56.17	57.00	56.33	53.83	53.67
	2E-05	74.33	75.50	75.00	75.33	75.83	56.33	56.17	56.50	54.33	53.33
	2E-06	73.17	74.00	73.83	74.33	73.83	55.00	55.83	55.00	54.67	53.83
	2E-07	73.50	74.00	73.50	73.83	74.33	56.33	56.67	57.17	55.17	54.67
	2E-08	70.33	72.17	72.00	71.83	72.50	52.33	52.33	51.33	52.17	51.33
	2E-09	71.17	72.33	71.33	72.17	72.50	52.00	52.17	52.17	51.67	50.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 103 – Taxa de reconhecimento da técnica *Gappy* PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	52.92	52.00	52.00	51.83	50.58	45.50	44.50	45.00	43.25	41.00
	2E-04	71.00	72.50	72.08	71.08	71.42	81.75	81.25	81.75	81.00	82.25
	2E-05	71.08	71.42	71.25	70.92	70.92	85.25	84.75	84.50	84.75	85.00
	2E-06	70.75	70.92	70.75	70.00	70.25	86.00	85.50	86.00	85.75	85.25
	2E-07	70.50	70.92	70.83	70.42	70.92	85.25	85.50	85.25	84.25	84.75
	2E-08	63.75	64.92	64.33	64.58	65.25	75.75	77.00	76.50	76.75	76.75
	2E-09	63.08	64.58	64.00	64.25	64.67	75.50	77.00	76.25	77.00	77.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	84.83	84.00	84.83	83.50	83.33	55.83	54.00	55.33	51.00	48.83
	2E-04	90.00	90.50	90.50	90.67	90.83	75.33	75.33	75.50	73.33	73.33
	2E-05	88.50	88.33	88.50	89.00	89.33	77.00	76.33	77.00	74.50	74.33
	2E-06	87.50	87.83	87.67	88.17	88.17	76.33	76.33	76.67	75.17	74.33
	2E-07	87.50	88.00	88.00	88.00	88.17	74.83	74.83	74.83	74.50	74.17
	2E-08	82.67	84.17	83.33	84.00	84.00	71.50	72.17	71.83	71.00	71.83
	2E-09	82.50	84.00	83.33	83.33	84.17	71.33	72.00	71.67	70.83	71.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 104 – Taxa de reconhecimento da técnica PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	13.17	13.58	13.67	12.92	12.42	12.00	11.75	12.00	11.25	11.00
	2E-04	32.42	33.50	33.08	31.25	30.92	44.75	46.75	45.50	44.00	44.00
	2E-05	31.58	32.67	32.00	31.33	31.67	50.00	50.50	50.50	49.50	48.50
	2E-06	31.42	32.58	32.08	31.17	31.42	50.75	51.25	51.00	49.25	48.75
	2E-07	32.83	33.92	33.42	32.75	32.83	51.25	54.25	53.00	50.50	51.25
	2E-08	30.17	31.50	31.17	29.83	29.67	44.00	45.75	44.75	44.00	44.00
	2E-09	30.08	31.25	30.83	29.75	29.50	43.00	46.75	45.25	43.50	43.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	47.00	47.50	47.50	46.50	44.67	37.67	37.17	37.17	34.33	33.67
	2E-04	58.67	59.17	59.50	58.00	58.17	58.50	59.33	59.00	57.83	57.33
	2E-05	56.67	56.83	56.83	55.67	54.83	55.17	55.83	55.67	54.33	54.00
	2E-06	54.33	54.83	54.67	53.67	54.00	54.67	55.17	55.00	53.83	52.83
	2E-07	56.33	57.50	57.67	55.17	55.50	56.50	56.83	56.83	54.83	54.17
	2E-08	53.17	54.17	54.00	53.17	53.67	57.67	58.67	57.17	56.33	55.33
	2E-09	53.50	54.00	54.17	53.17	52.83	56.67	58.33	57.33	56.17	55.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 105 – Taxa de reconhecimento da técnica *Recursive* PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	54.92	54.92	54.33	53.83	52.00	52.75	48.75	51.25	48.50	47.50
	2E-04	76.33	77.00	77.08	75.92	76.33	87.00	87.50	87.75	86.75	86.50
	2E-05	76.33	77.08	76.58	75.33	75.67	88.50	88.75	88.50	88.75	88.75
	2E-06	75.92	76.92	76.58	75.33	75.50	88.25	88.75	88.75	89.00	88.75
	2E-07	74.58	75.83	75.42	75.42	75.17	88.00	88.75	88.25	88.00	88.50
	2E-08	69.25	70.83	70.42	70.08	70.33	82.00	82.25	82.25	82.00	81.50
	2E-09	69.08	70.58	70.67	70.17	70.33	81.75	82.25	82.25	81.50	81.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	86.67	86.00	86.33	86.67	86.83	62.00	61.17	61.83	57.83	55.83
	2E-04	91.83	92.67	92.67	92.83	93.17	83.17	82.83	83.17	81.33	81.33
	2E-05	91.50	91.17	91.33	91.50	91.67	83.50	83.83	83.83	82.00	81.67
	2E-06	90.33	89.83	90.00	90.50	90.83	83.33	83.33	83.50	82.17	81.83
	2E-07	91.17	91.00	91.17	91.00	91.00	81.67	81.83	82.67	80.50	80.50
	2E-08	87.00	88.67	88.00	87.67	88.83	79.17	79.33	79.17	77.67	77.33
	2E-09	86.67	88.33	88.17	87.33	88.83	79.33	79.17	79.00	78.33	77.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 106 – Taxa de reconhecimento da técnica SRC com *Fast Recursive* PCA com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	85.25	85.33	85.25	84.67	84.17	92.50	92.75	92.75	92.50	91.75
	2E-04	90.42	90.33	90.50	90.25	90.33	94.50	95.00	94.75	95.00	95.00
	2E-05	89.92	90.08	90.00	89.92	90.08	94.25	94.25	94.25	94.25	94.25
	2E-06	89.92	89.75	90.00	89.67	89.58	94.50	94.25	94.25	94.25	94.25
	2E-07	89.17	89.33	89.00	89.17	89.17	94.25	94.25	94.25	94.25	94.25
	2E-08	88.83	88.83	88.83	88.58	88.58	93.50	93.50	93.50	93.50	93.50
	2E-09	88.83	88.75	88.75	88.67	88.50	93.50	93.50	93.50	93.50	93.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	96.17	96.17	96.17	96.17	96.17	78.33	77.83	78.17	78.00	77.83
	2E-04	96.33	96.33	96.33	96.33	96.33	85.83	85.83	85.83	85.83	85.83
	2E-05	96.00	96.00	96.00	96.00	96.00	85.50	85.50	85.50	85.00	85.00
	2E-06	96.00	96.00	96.00	96.17	96.17	85.00	85.00	85.33	84.67	84.67
	2E-07	96.00	95.83	95.83	96.17	96.00	84.00	83.83	83.83	83.33	83.33
	2E-08	95.83	95.83	96.00	95.67	95.83	84.33	83.67	83.67	82.83	82.67
	2E-09	96.00	95.83	96.00	95.67	95.83	83.67	83.67	83.50	83.00	82.50

Fonte: Jonas Mendonça Targino. 2019

E.2 Resultados de reconstrução com técnicas baseadas em modelo

E.2.1 Resultados com ELM

Tabela 107 – Taxa de reconhecimento da SRC com grafo de Poisson na base de dados AR com ELM com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	70.42±0.31	70.40±0.53691	70.05±0.42	69.77±0.29	70.02±0.40
	500	70.09±0.41	70.20±0.31975	70.05±0.23	69.67±0.44	69.56±0.49
	1000	68.32±0.44	68.27±0.27513	68.09±0.40	67.92±0.48	67.75±0.41
	2000	68.31±0.30	68.55±0.56819	68.30±0.37	67.90±0.20	67.99±0.52
	4000	69.74±0.27	69.79±0.31732	69.81±0.25	69.11±0.20	68.96±0.34

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	83.17±0.26	83.10±0.21	82.90±0.21	82.97±0.29	82.97±0.32
	500	82.87±0.17	82.92±0.23	82.50±0.11	82.47±0.07	82.85±0.24
	1000	82.72±0.27	82.72±0.14	82.62±0.37	82.45±0.19	82.75±0.33
	2000	82.72±0.27	82.72±0.24	82.65±0.21	82.47±0.21	82.60±0.17
	4000	82.70±0.15	82.70±0.15	82.50±0.00	82.47±0.07	82.52±0.07

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	83.81±0.28	83.71±0.23	83.85±0.24	83.88±0.28	83.81±0.27
	500	83.60±0.25	83.63±0.20	83.50±0.15	83.55±0.15	83.51±0.22
	1000	83.65±0.27	83.40±0.52	83.38±0.24	83.40±0.22	83.26±0.25
	2000	83.43±0.27	83.41±0.36	83.48±0.18	83.16±0.11	83.30±0.29
	4000	83.46±0.13	83.45±0.15	83.50±0.22	83.20±0.07	83.21±0.08

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	57.03±0.64	57.08±1.06	56.26±0.89	55.66±0.46	56.23±0.94
	500	56.58±0.68	56.78±0.59	56.60±0.41	55.80±0.81	55.61±0.85
	1000	53.00±0.81	53.15±0.67	52.80±0.83	52.45±1.05	52.25±0.88
	2000	53.20±0.56	53.68±1.02	53.13±0.64	52.65±0.43	52.68±0.89
	4000	56.01±0.50	56.13±0.53	56.13±0.34	55.03±0.40	54.71±0.62

Fonte: Jonas Mendonça Targino. 2019

Tabela 108 – Taxa de reconhecimento da SRC com grafo Laplaciano na base de dados AR com ELM com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	71.94±0.38	72.09±0.40	71.58±0.43	71.45±0.39	71.75±0.49
	500	71.72±0.23	71.85±0.51	71.55±0.26	71.41±0.47	71.24±0.40
	1000	69.76±0.55	69.67±0.27	69.58±0.47	69.54±0.44	69.11±0.40
	2000	69.87±0.43	69.86±0.47	69.76±0.39	69.43±0.28	69.52±0.49
	4000	71.30±0.28	71.45±0.22	71.27±0.27	70.43±0.18	70.58±0.40

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	84.02±0.07	84.12±0.35	83.85±0.24	83.80±0.25	83.87±0.27
	500	83.90±0.21	83.90±0.21	83.52±0.18	83.47±0.07	83.70±0.25
	1000	83.82±0.28	83.85±0.24	83.55±0.34	83.40±0.24	83.65±0.29
	2000	83.87±0.31	83.70±0.22	83.65±0.21	83.45±0.19	83.60±0.17
	4000	83.77±0.14	83.65±0.17	83.52±0.07	83.47±0.07	83.60±0.12

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	85.58±0.26	85.65±0.25	85.65±0.31	85.73±0.23	85.75±0.28
	500	85.55±0.15	85.71±0.20	85.45±0.19	85.58±0.21	85.48±0.25
	1000	85.55±0.31	85.28±0.56	85.33±0.35	85.35±0.30	85.10±0.32
	2000	85.43±0.33	85.31±0.44	85.50±0.23	85.06±0.14	85.26±0.17
	4000	85.53±0.15	85.63±0.17	85.55±0.27	85.06±0.11	85.18±0.16

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	58.30±0.75	58.53±0.87	57.51±0.82	57.18±0.61	57.76±1.00
	500	57.90±0.42	57.98±0.95	57.66±0.47	57.25±0.82	57.00±0.63
	1000	53.98±1.01	54.06±0.67	53.83±0.77	53.73±0.99	53.13±0.85
	2000	54.31±0.75	54.41±0.83	54.03±0.71	53.80±0.51	53.78±0.85
	4000	57.06±0.52	57.26±0.38	57.00±0.38	55.80±0.33	55.98±0.76

Fonte: Jonas Mendonça Targino. 2019

Tabela 109 – Taxa de reconhecimento da técnica SSIMGL na base de dados AR com ELM com nível de decomposição LL3

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	92.27±0.41	92.40±0.60	91.98±0.84	92.16±0.44	91.55±0.66
	500	92.90±0.27	93.01±0.58	92.80±0.40	93.00±0.49	92.45±0.58
	1000	87.00±0.75	87.54±0.45	87.43±0.54	87.25±0.59	86.33±0.89
	2000	87.90±0.74	88.54±0.38	88.15±0.54	88.08±0.79	87.66±0.66
	40000	93.00±0.60	93.12±0.32	93.38±0.35	92.83±0.25	92.49±0.34

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.27±0.21	95.35±0.24	95.35±0.29	95.50±0.28	95.50±0.20
	500	95.52±0.14	95.55±0.15	95.45±0.10	95.55±0.15	95.40±0.12
	1000	95.05±0.36	94.90±0.21	94.82±0.35	95.05±0.30	95.05±0.30
	2000	94.80±0.25	94.87±0.29	94.80±0.32	95.12±0.21	95.00±0.33
	40000	95.00±0.20	95.15±0.17	95.15±0.12	95.30±0.10	95.25±0.11

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.83±0.34	95.96±0.24	96.05±0.37	96.11±0.30	96.00±0.26
	500	96.01±0.14	96.25±0.23	96.23±0.31	96.35±0.31	95.93±0.27
	1000	95.56±0.42	95.23±0.23	95.46±0.43	95.48±0.31	95.05±0.38
	2000	95.70±0.17	95.48±0.49	95.48±0.28	95.46±0.32	95.31±0.32
	4000	96.23±0.21	96.13±0.15	96.25±0.19	96.10±0.16	96.13±0.17

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
	200	88.71±0.80	88.83±1.03	87.91±1.42	88.21±0.76	87.10±1.27
	500	89.78±0.58	89.78±1.07	89.38±0.68	89.65±0.93	88.96±1.04
	1000	78.45±1.41	79.85±0.80	79.40±1.21	79.01±1.28	77.61±1.96
	2000	80.10±1.46	81.60±0.83	80.83±1.13	80.7±1.54	80.01±1.32
	4000	89.76±1.16	90.11±0.59	90.51±0.64	89.56±0.47	88.85±0.66

Fonte: Jonas Mendonça Targino. 2019

Tabela 110 – Taxa de reconhecimento da similaridade estrutural com Grafo Laplaciano na base de dados Yale com ELM com nível de decomposição LL3

		Yale#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	99.33±2.10	98.66±2.81	100.00±0.00	98.66±2.81	99.33±2.10
	500	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	1000	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	2000	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	4000	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00

		Yale#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurónios	200	99.33±2.10	98.66±2.81	100.00±0.00	97.33±3.44	100.00±0.00
	500	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	1000	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	2000	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	4000	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00

Fonte: Jonas Mendonça Targino. 2019

ELM nível LL2

Tabela 111 – Taxa de reconhecimento SRC com Grafo de Poisson na base de dados AR com ELM com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	70.10±0.44	70.29±0.33	70.28±0.54	69.96±0.52	70.15±0.40
	500	70.78±0.43	70.54±0.29	71.09±0.40	70.33±0.34	70.66±0.23
	1000	69.75±0.25	70.01±0.42	70.25±0.48	69.54±0.21	69.32±0.46
	2000	70.14±0.32	69.99±0.50	70.13±0.70	69.50±0.30	69.75±0.33
	4000	70.40±0.20	70.53±0.30	70.65±0.20	70.18±0.30	70.12±0.13

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	82.82±0.26	82.77±0.18	82.92±0.35	82.80±0.30	82.80±0.25
	500	82.82±0.31	82.65±0.17	82.87±0.13	82.80±0.15	82.82±0.26
	1000	83.02±0.38	82.77±0.18	82.90±0.29	82.82±0.26	83.02±0.36
	2000	82.90±0.21	82.95±0.15	82.92±0.20	82.77±0.18	82.90±0.17
	4000	82.77±0.21	82.90±0.17	82.72±0.18	82.85±0.17	82.82±0.16

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	83.61±0.31	83.71±0.23	83.58±0.18	83.58±0.25	83.60±0.19
	500	83.55±0.23	83.48±0.16	83.35±0.12	83.41±0.08	83.46±0.17
	1000	83.46±0.29	83.43±0.11	83.45±0.19	83.43±0.26	83.53±0.18
	2000	83.48±0.22	83.48±0.24	83.38±0.22	83.36±0.15	83.40±0.23
	4000	83.26±0.08	83.26±0.08	83.21±0.08	83.20±0.07	83.21±0.08

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	56.58±0.91	56.86±0.64	56.98±1.00	56.35±1.04	56.71±0.62
	500	58.01±0.83	57.60±0.65	58.83±0.79	57.25±0.69	57.86±0.44
	1000	56.03±0.56	56.60±0.82	57.06±1.01	55.65±0.44	55.11±1.04
	2000	56.80±0.78	56.50±1.05	56.88±1.39	55.63±0.53	56.11±0.81
	4000	57.55±0.40	57.80±0.65	58.08±0.41	57.16±0.62	57.03±0.30

Fonte: Jonas Mendonça Targino. 2019

Tabela 112 – Taxa de reconhecimento da SRC com grafo Laplaciano base de dados AR com ELM com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	71.50±0.37	71.79±0.40	71.74±0.39	71.52±0.35	71.40±0.36
	500	72.26±0.37	71.80±0.24	72.39±0.39	71.85±0.30	72.08±0.22
	1000	71.22±0.25	71.49±0.43	71.63±0.52	71.10±0.28	70.86±0.49
	2000	71.45±0.35	71.56±0.46	71.43±0.61	71.05±0.37	71.36±0.46
	4000	71.79±0.21	71.93±0.21	72.00±0.31	71.50±0.22	71.58±0.20

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	83.75±0.23	83.82±0.12	83.85±0.31	83.77±0.34	83.67±0.16
	500	83.75±0.35	83.57±0.12	83.62±0.13	83.60±0.12	83.70±0.15
	1000	83.97±0.32	83.75±0.23	83.80±0.30	83.77±0.14	83.95±0.28
	2000	83.95±0.15	83.85±0.12	83.90±0.26	83.75±0.16	83.90±0.17
	4000	83.72±0.14	83.87±0.13	83.57±0.12	83.75±0.15	83.77±0.14

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	85.50±0.27	85.61±0.26	85.38±0.17	85.48±0.18	85.41±0.22
	500	85.45±0.19	85.35±0.09	85.35±0.12	85.38±0.20	85.43±0.11
	1000	85.43±0.27	85.35±0.12	85.45±0.22	85.33±0.22	85.51±0.27
	2000	85.46±0.21	85.45±0.23	85.38±0.23	85.36±0.15	85.36±0.15
	4000	85.30±0.10	85.26±0.08	85.25±0.11	85.20±0.07	85.21±0.08

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	57.50±0.81	57.78±0.67	58.10±0.74	57.56±0.72	57.38±0.63
	500	59.08±0.75	58.46±0.54	59.43±0.82	58.33±0.69	58.73±0.45
	1000	57.01±0.47	57.63±0.83	57.81±1.04	56.88±0.58	56.21±0.99
	2000	57.43±0.79	57.68±0.95	57.48±1.22	56.75±0.66	57.36±0.96
	4000	58.28±0.44	58.60±0.48	58.76±0.60	57.81±0.45	57.95±0.43

Fonte: Jonas Mendonça Targino. 2019

Tabela 113 – Taxa de reconhecimento da técnica SSIMGL na base de dados AR com ELM com nível de decomposição LL2

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	91.97±0.60	92.65±0.36	92.43±0.78	92.35±0.57	92.19±0.56
	500	94.00±0.45	94.09±0.27	94.35±0.25	94.22±0.42	93.74±0.33
	1000	91.62±0.38	92.08±0.61	92.05±0.51	92.11±0.33	91.11±0.61
	2000	93.09±0.55	93.23±0.47	93.02±0.37	92.62±0.69	92.74±0.48
	4000	94.86±0.11	94.92±0.21	94.96±0.18	95.02±0.13	94.70±0.22

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.47±0.18	95.45±0.28	95.40±0.12	95.50±0.20	95.42±0.20
	500	95.50±0.00	95.50±0.11	95.60±0.12	95.57±0.12	95.55±0.10
	1000	95.45±0.15	95.40±0.26	95.50±0.16	95.47±0.14	95.47±0.21
	2000	95.50±0.11	95.47±0.14	95.50±0.00	95.45±0.10	95.47±0.14
	4000	95.50±0.00	95.50±0.00	95.50±0.00	95.50±0.00	95.50±0.00

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.93±0.34	96.03±0.18	95.88±0.29	95.98±0.21	96.08±0.29
	500	96.05±0.15	96.13±0.15	96.11±0.15	96.20±0.20	96.13±0.17
	1000	95.86±0.18	95.96±0.30	95.91±0.30	95.90±0.25	96.03±0.32
	2000	96.06±0.17	96.05±0.13	96.08±0.18	96.01±0.26	96.16±0.31
	4000	96.03±0.07	96.18±0.12	96.13±0.10	96.20±0.07	96.23±0.11

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
	200	88.01±1.21	89.26±0.76	88.98±1.61	88.71±1.10	88.30±1.07
	500	91.96±0.89	92.05±0.52	92.58±0.58	92.25±0.78	91.35±0.65
	1000	87.38±0.88	88.20±1.15	88.18±1.27	88.33±0.82	86.20±1.16
	2000	90.11±1.06	90.41±0.91	89.96±0.66	89.23±1.24	89.31±0.95
	4000	93.70±0.25	93.66±0.41	93.80±0.34	93.85±0.24	93.18±0.44

Fonte: Jonas Mendonça Targino. 2019

ELM nível LL1

Tabela 114 – Taxa de reconhecimento da técnica SRC Grafo com Poisson na base de dados AR com ELM com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	69.37±0.45	69.51±0.41	69.36±0.57	69.32±0.37	69.24±0.33
	500	70.23±0.47	70.16±0.51	70.20±0.42	70.00±0.50	69.95±0.42
	1000	69.13±0.43	69.27±0.40	69.56±0.51	69.04±0.27	69.15±0.33
	2000	69.56±0.35	69.80±0.33	69.79±0.44	69.66±0.46	69.60±0.28
	4000	70.34±0.26	70.29±0.29	70.30±0.22	70.19±0.23	69.99±0.31

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	82.62±0.44	82.97±0.21	82.80±0.34	82.75±0.20	82.67±0.28
	500	82.72±0.18	82.77±0.21	82.72±0.18	82.72±0.14	82.72±0.14
	1000	82.85±0.21	82.85±0.12	82.90±0.26	82.67±0.20	82.72±0.18
	2000	82.87±0.21	82.82±0.20	82.67±0.23	82.80±0.25	82.70±0.15
	4000	82.60±0.12	82.62±0.17	82.65±0.12	82.60±0.12	82.55±0.10

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	83.56±0.32	83.58±0.30	83.50±0.28	83.56±0.40	83.48±0.31
	500	83.35±0.16	83.40±0.29	83.43±0.11	83.40±0.16	83.45±0.20
	1000	83.38±0.20	83.41±0.19	83.40±0.26	83.26±0.21	83.38±0.15
	2000	83.31±0.12	83.33±0.15	83.36±0.15	83.40±0.16	83.25±0.11
	4000	83.21±0.08	83.20±0.07	83.21±0.08	83.21±0.08	83.16±0.00

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	55.18±0.80	55.45±0.84	55.23±1.08	55.08±0.98	55.00±0.63
	500	57.11±0.85	56.93±0.91	56.98±0.84	56.60±0.89	56.46±0.78
	1000	54.88±0.87	55.13±0.75	55.73±0.95	54.81±0.56	54.91±0.71
	2000	55.81±0.69	56.28±0.59	56.21±0.78	55.93±0.87	55.96±0.59
	4000	57.46±0.57	57.38±0.58	57.40±0.39	57.16±0.43	56.81±0.63

Fonte: Jonas Mendonça Targino. 2019

Tabela 115 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano na base de dados AR com ELM com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	70.92±0.46	70.92±0.38	70.89±0.55	70.70±0.28	70.78±0.33
	500	71.70±0.40	71.63±0.59	71.52±0.45	71.53±0.55	71.50±0.52
	1000	70.58±0.54	70.69±0.33	70.94±0.42	70.57±0.29	70.69±0.26
	2000	71.05±0.33	71.27±0.33	71.24±0.35	71.14±0.40	71.20±0.36
	4000	71.80±0.19	71.61±0.28	71.68±0.30	71.56±0.29	71.45±0.28

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	83.65±0.41	83.82±0.28	83.67±0.28	83.72±0.24	83.67±0.23
	500	83.70±0.22	83.70±0.22	83.62±0.13	83.60±0.12	83.65±0.17
	1000	83.85±0.26	83.77±0.14	83.72±0.18	83.75±0.20	83.65±0.24
	2000	83.75±0.16	83.75±0.20	83.65±0.21	83.77±0.18	83.70±0.22
	4000	83.62±0.13	83.57±0.12	83.55±0.10	83.65±0.12	83.52±0.07

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	85.36±0.26	85.53±0.32	85.36±0.29	85.43±0.42	85.43±0.34
	500	85.30±0.17	85.35±0.25	85.41±0.11	85.33±0.13	85.41±0.22
	1000	85.38±0.23	85.31±0.14	85.38±0.26	85.23±0.25	85.36±0.25
	2000	85.26±0.11	85.33±0.13	85.31±0.09	85.31±0.12	85.25±0.11
	4000	85.21±0.08	85.20±0.07	85.21±0.08	85.21±0.08	85.16±0.00

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	56.48±0.75	56.31±0.78	56.41±1.11	55.98±0.63	56.13±0.61
	500	58.11±0.78	57.91±1.05	57.63±0.92	57.73±1.09	57.60±0.94
	1000	55.78±1.07	56.06±0.64	56.50±0.78	55.91±0.64	56.01±0.60
	2000	56.83±0.71	57.21±0.60	57.16±0.66	56.96±0.76	57.15±0.69
	4000	58.40±0.40	58.03±0.57	58.15±0.55	57.91±0.56	57.73±0.56

Fonte: Jonas Mendonça Targino. 2019

Tabela 116 – Taxa de reconhecimento da técnica SSIMGL na base de dados AR com ELM com nível de decomposição LL1

		AR#1				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	90.31±0.74	90.29±0.63	90.10±0.70	89.96±0.83	89.94±0.63
	500	93.00±0.52	93.15±0.50	93.16±0.46	92.88±0.34	93.19±0.40
	1000	90.68±0.71	91.24±0.57	90.95±0.76	90.60±0.80	91.08±0.75
	2000	92.93±0.46	93.02±0.32	93.10±0.50	92.74±0.38	93.03±0.37
	4000	94.83±0.21	94.89±0.17	94.93±0.14	94.84±0.21	94.90±0.08

		AR#2				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.02±0.34	95.30±0.42	94.92±0.37	95.07±0.37	95.07±0.37
	500	95.42±0.16	95.47±0.14	95.37±0.17	95.42±0.12	95.37±0.21
	1000	95.30±0.19	95.32±0.40	95.25±0.20	95.30±0.15	95.35±0.17
	2000	95.40±0.12	95.42±0.12	95.42±0.16	95.45±0.15	95.45±0.15
	4000	95.50±0.00	95.50±0.00	95.50±0.00	95.52±0.07	95.50±0.00

		AR#3				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	95.56±0.45	95.71±0.52	95.60±0.50	95.53±0.38	95.43±0.41
	500	96.03±0.20	96.03±0.28	96.10±0.19	95.91±0.21	95.95±0.29
	1000	95.73±0.28	95.73±0.16	95.81±0.38	95.73±0.17	95.88±0.24
	2000	95.98±0.12	95.95±0.19	96.10±0.17	95.96±0.17	96.03±0.23
	4000	96.03±0.07	96.06±0.08	96.06±0.08	96.06±0.11	96.03±0.07

		AR#4				
		db2	db4	sym3	sym4	sym5
		$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Neurônios	200	85.06±1.60	84.86±1.20	84.60±1.29	84.40±1.72	84.45±1.26
	500	89.96±1.00	90.26±0.97	90.23±0.93	89.85±0.65	90.43±0.84
	1000	85.63±1.34	86.75±1.05	86.08±1.48	85.46±1.52	86.28±1.44
	2000	89.88±0.90	90.10±0.66	90.11±0.91	89.51±0.78	90.03±0.68
	4000	93.63±0.42	93.71±0.32	93.80±0.24	93.61±0.43	93.76±0.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 117 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador KNN com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	68.00	68.17	67.92	66.25	66.67	82.50	82.50	82.50	81.50	81.75
	2	68.00	68.17	67.92	66.25	66.67	82.50	82.50	82.50	81.50	81.75
	4	66.08	65.58	65.67	63.92	64.50	80.75	80.25	80.75	78.50	79.00
	6	64.83	64.17	63.00	61.50	61.42	80.75	79.50	80.00	77.50	77.25
	8	63.92	62.08	61.83	58.33	59.58	79.75	78.25	78.75	75.75	76.25
	10	62.42	60.75	61.17	57.33	57.67	79.50	76.75	78.50	75.00	75.25

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	83.33	83.17	83.50	82.00	82.50	52.67	53.17	52.33	50.50	50.83
	2	83.33	83.17	83.50	82.00	82.50	52.67	53.17	52.33	50.50	50.83
	4	80.50	79.00	79.83	77.67	78.50	51.67	52.17	51.50	50.17	50.50
	6	78.33	76.33	74.83	73.83	73.83	51.33	52.00	51.17	49.17	49.00
	8	77.00	73.83	73.83	69.33	70.83	50.83	50.33	49.83	47.33	48.33
	10	74.67	72.50	72.83	68.50	69.33	50.17	49.00	49.50	46.17	46.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 118 – Taxa de reconhecimento da técnica SRC com grafo de Laplace com classificador KNN com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	69.58	69.33	69.50	67.58	67.83	83.50	83.25	83.25	82.25	82.25
	2	69.58	69.33	69.50	67.58	67.83	83.50	83.25	83.25	82.25	82.25
	4	67.58	66.67	66.67	65.00	65.42	82.50	80.50	81.00	78.50	79.25
	6	65.67	64.58	64.25	62.25	61.58	81.75	79.50	80.75	77.25	76.75
	8	64.92	63.25	63.42	59.42	60.00	80.50	77.50	79.00	75.50	75.75
	10	63.00	61.83	62.75	57.67	58.00	79.25	76.50	79.00	74.25	74.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	85.33	84.83	85.17	83.50	83.67	53.83	53.83	53.83	51.67	52.00
	2	85.33	84.83	85.17	83.50	83.67	53.83	53.83	53.83	51.67	52.00
	4	82.50	80.67	80.83	78.50	79.33	52.67	52.67	52.50	51.50	51.50
	6	79.50	77.50	77.17	75.17	74.17	51.83	51.67	51.33	49.33	49.00
	8	78.50	75.83	76.33	70.83	71.33	51.33	50.67	50.50	48.00	48.67
	10	76.17	73.67	74.83	68.67	69.67	49.83	50.00	50.67	46.67	46.33

Fonte: Jonas Mendonça Targino. 2019

E.2.2 Resultados com KNN

Tabela 119 – Taxa de reconhecimento com KNN na base AR com a técnica SSIMGL com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	87.00	85.83	86.08	81.83	81.50	93.75	93.50	93.50	90.25	90.00
	2	87.00	85.83	86.08	81.83	81.50	93.75	93.50	93.50	90.25	90.00
	4	83.75	81.75	82.75	78.50	77.75	92.00	90.00	90.25	85.00	85.25
	6	81.08	79.42	80.00	75.58	75.42	91.00	89.50	90.25	84.50	84.75
	8	79.83	77.33	77.67	72.50	73.08	90.25	88.00	89.00	83.50	83.75
	10	78.33	75.25	77.17	70.17	71.33	89.25	85.50	88.75	82.75	83.00
		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	94.67	92.67	93.17	88.67	89.00	79.33	79.00	79.00	75.00	74.00
	2	94.67	92.67	93.17	88.67	89.00	79.33	79.00	79.00	75.00	74.00
	4	91.17	87.67	88.50	84.50	84.67	76.33	75.83	77.00	72.50	70.83
	6	87.00	84.67	84.67	79.83	81.33	75.17	74.17	75.33	71.33	69.50
	8	85.67	81.33	82.67	76.83	77.33	74.00	73.33	72.67	68.17	68.83
	10	83.50	78.83	81.50	74.83	75.67	73.17	71.67	72.83	65.50	67.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 120 – Taxa de reconhecimento com KNN na base de dados Yale após reconstrução com SSIMGL com nível de decomposição LL3

		Yale#1				
		db2	db4	sym3	sym4	sym5
K-vizinhos	1	100.00	100.00	100.00	100.00	100.00
	2	100.00	100.00	100.00	100.00	100.00
	4	100.00	100.00	100.00	100.00	100.00
	6	100.00	100.00	100.00	100.00	100.00
	8	100.00	93.33	100.00	93.33	93.33
	10	93.33	93.33	93.33	93.33	93.33
		Yale#2				
		db2	db4	sym3	sym4	sym5
K-vizinhos	1	100.00	100.00	100.00	100.00	100.00
	2	100.00	100.00	100.00	100.00	100.00
	4	100.00	100.00	100.00	100.00	100.00
	6	100.00	100.00	100.00	100.00	100.00
	8	100.00	93.33	100.00	93.33	93.33
	10	93.33	93.33	93.33	93.33	93.33

Fonte: Jonas Mendonça Targino. 2019

KNN nível LL2

Tabela 121 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador KNN com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	68.17	68.75	68.42	67.92	67.92	82.50	82.75	82.50	82.50	82.50
	2	68.17	68.75	68.42	67.92	67.92	82.50	82.75	82.50	82.50	82.50
	4	66.92	67.00	66.83	65.83	65.75	81.50	81.50	81.50	80.00	80.00
	6	65.58	65.25	65.50	64.25	63.83	81.25	81.25	81.25	80.00	80.00
	8	64.42	63.83	64.17	62.58	61.83	80.25	80.25	79.50	79.25	78.25
	10	63.67	63.33	63.50	61.50	61.58	79.50	80.00	79.50	78.50	78.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	83.17	83.50	83.17	83.00	83.17	53.17	54.00	53.67	52.83	52.67
	2	83.17	83.50	83.17	83.00	83.17	53.17	54.00	53.67	52.83	52.67
	4	81.50	81.00	80.83	79.50	79.67	52.33	53.00	52.83	52.17	51.83
	6	79.67	77.67	79.00	77.67	76.50	51.50	52.83	52.00	50.83	51.17
	8	77.33	75.83	77.00	74.67	74.00	51.50	51.83	51.33	50.50	49.67
	10	76.17	75.00	76.33	73.00	73.50	51.17	51.67	50.67	50.00	49.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 123 – Taxa de reconhecimento com KNN na base AR com a técnica SSIMGL com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	87.92	88.67	88.25	87.58	87.00	94.00	94.00	94.25	94.00	94.00
	2	87.92	88.67	88.25	87.58	87.00	94.00	94.00	94.25	94.00	94.00
	4	85.42	85.75	85.50	84.75	84.17	92.50	92.00	93.25	91.50	91.50
	6	84.25	83.33	83.67	82.33	80.83	93.00	91.75	93.00	90.50	90.00
	8	81.75	81.58	82.00	79.58	78.58	90.25	89.75	90.75	88.75	88.00
	10	80.75	81.08	81.17	78.42	77.75	90.50	90.00	91.00	88.25	87.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
K-vizinhos	1	94.67	94.50	94.67	93.67	93.83	81.17	82.83	81.83	81.50	80.17
	2	94.67	94.50	94.67	93.67	93.83	81.17	82.83	81.83	81.50	80.17
	4	92.50	91.83	92.33	90.50	90.67	78.33	79.67	78.67	79.00	77.67
	6	91.33	88.33	89.83	88.00	86.33	77.17	78.33	77.50	76.67	75.33
	8	88.33	85.67	86.83	83.17	83.50	75.17	77.50	77.17	76.00	73.67
	10	86.00	85.67	85.33	83.00	82.33	75.50	76.50	77.00	73.83	73.17

Fonte: Jonas Mendonça Targino. 2019

KNN nível LL1

Tabela 122 – Taxa de reconhecimento da técnica SRC com grafo de Laplace com classificador KNN com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	69.83	70.42	70.08	69.42	69.33	83.50	83.75	83.50	83.25	83.25
	2	69.83	70.42	70.08	69.42	69.33	83.50	83.75	83.50	83.25	83.25
	4	68.58	68.42	68.42	67.33	67.25	82.75	82.75	82.75	81.00	80.75
	6	67.50	66.75	67.33	65.33	65.00	82.75	82.00	82.50	80.50	80.25
	8	65.92	64.92	65.83	63.25	62.83	81.00	80.50	81.00	79.25	78.00
	10	65.25	64.08	64.83	62.75	62.67	80.75	80.50	80.75	78.75	78.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	85.17	85.67	85.17	84.67	84.83	54.50	55.17	55.00	54.17	53.83
	2	85.17	85.67	85.17	84.67	84.83	54.50	55.17	55.00	54.17	53.83
	4	83.50	83.00	83.00	81.17	81.50	53.67	53.83	53.83	53.50	53.00
	6	82.33	80.17	81.33	79.17	78.33	52.67	53.33	53.33	51.50	51.67
	8	79.83	77.83	79.50	75.83	75.50	52.00	52.00	52.17	50.67	50.17
	10	78.67	76.50	78.17	74.50	74.67	51.83	51.67	51.50	51.00	50.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 124 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador KNN com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	68.17	68.25	68.17	68.25	68.25	82.50	82.50	82.50	82.50	82.50
	2	68.17	68.25	68.17	68.25	68.25	82.50	82.50	82.50	82.50	82.50
	4	66.67	67.08	66.75	66.58	66.50	81.25	81.25	81.25	81.25	81.25
	6	65.33	65.58	65.33	64.75	65.00	81.00	80.75	80.75	80.75	81.00
	8	64.00	64.25	63.92	63.92	63.33	80.00	80.00	80.00	79.25	78.50
	10	63.75	63.75	63.67	63.17	63.00	80.00	80.00	79.75	78.75	78.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	83.17	83.17	83.17	83.17	83.17	53.17	53.33	53.17	53.33	53.33
	2	83.17	83.17	83.17	83.17	83.17	53.17	53.33	53.17	53.33	53.33
	4	81.33	81.33	81.17	81.17	80.83	52.00	52.83	52.33	52.00	52.17
	6	79.83	79.50	79.67	78.50	79.17	50.83	51.67	51.00	51.00	50.83
	8	78.00	77.83	77.83	77.50	76.50	50.00	50.67	50.00	50.33	50.17
	10	76.67	76.50	76.50	76.00	75.50	50.83	51.00	50.83	50.33	50.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 125 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador KNN com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	69.83	70.08	69.83	70.00	69.92	83.50	83.50	83.50	83.50	83.50
	2	69.83	70.08	69.83	70.00	69.92	83.50	83.50	83.50	83.50	83.50
	4	67.92	68.58	68.17	67.83	68.00	82.25	82.50	82.50	82.25	82.25
	6	67.08	67.50	66.92	66.75	67.00	82.50	82.00	82.00	82.00	82.00
	8	65.67	66.08	65.58	65.67	65.17	81.25	81.25	81.25	80.25	79.25
	10	65.42	65.25	65.33	64.92	64.92	81.50	81.00	81.25	80.00	80.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	85.17	85.17	85.17	85.17	85.17	54.50	55.00	54.50	54.83	54.67
	2	85.17	85.17	85.17	85.17	85.17	54.50	55.00	54.50	54.83	54.67
	4	82.83	83.17	82.83	82.33	82.67	53.00	54.00	53.50	53.33	53.33
	6	82.33	82.00	81.83	81.50	81.33	51.83	53.00	52.00	52.00	52.67
	8	80.33	80.33	80.17	79.50	79.17	51.00	51.83	51.00	51.83	51.17
	10	79.17	78.83	78.83	78.17	78.00	51.67	51.67	51.83	51.67	51.83

Fonte: Jonas Mendonça Targino. 2019

Tabela 126 – Taxa de reconhecimento com KNN na base AR com a técnica SSIMGL com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	87.92	88.58	88.33	88.25	88.17	94.25	94.25	94.50	94.50	94.50
	2	87.92	88.58	88.33	88.25	88.17	94.25	94.25	94.50	94.50	94.50
	4	85.58	85.83	85.58	86.00	85.83	93.00	93.25	93.00	93.75	93.75
	6	83.75	84.08	84.00	84.17	84.08	92.25	92.25	92.50	92.25	92.00
	8	81.75	82.33	82.17	82.17	81.83	91.75	91.25	91.75	89.50	89.50
	10	81.08	81.08	81.50	80.50	80.42	91.25	90.75	91.25	89.25	88.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	K-vizinhos										
	1	94.67	94.50	94.67	94.67	94.67	81.17	82.67	82.00	81.83	81.67
	2	94.67	94.50	94.67	94.67	94.67	81.17	82.67	82.00	81.83	81.67
	4	92.83	92.50	92.67	93.00	93.17	78.33	79.17	78.50	79.00	78.50
	6	91.00	90.17	90.83	90.67	90.50	76.50	78.00	77.17	77.67	77.67
	8	88.83	88.33	88.83	89.00	88.33	74.67	76.33	75.50	75.33	75.33
	10	87.33	86.67	87.33	86.17	86.17	74.83	75.50	75.67	74.83	74.67

Fonte: Jonas Mendonça Targino. 2019

E.2.3 Resultados com SVM

Tabela 127 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	70.50	70.92	70.75	69.67	69.75	82.50	82.50	82.50	82.50	82.50
	2E-04	70.50	70.50	70.50	69.75	69.75	83.00	82.50	82.50	82.50	82.75
	2E-05	70.33	70.50	70.42	69.67	69.92	83.25	82.50	82.75	82.50	82.50
	2E-06	70.50	70.08	69.75	68.83	69.08	83.00	82.75	83.00	82.50	82.75
	2E-07	70.50	69.92	69.58	67.75	68.08	83.25	83.00	83.00	81.75	81.50
	2E-08	70.25	69.67	69.75	67.83	67.92	83.50	83.00	83.25	81.25	81.50
	2E-09	68.83	69.25	68.58	68.00	67.25	82.75	82.75	83.00	82.00	81.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	84.00	84.00	83.83	83.17	83.67	61.17	60.17	60.17	58.00	59.00
	2E-04	83.83	84.00	83.83	83.33	83.33	60.33	59.83	59.67	58.33	58.33
	2E-05	84.00	84.00	83.67	83.50	83.67	60.00	59.50	60.00	58.00	57.83
	2E-06	83.83	84.33	84.17	83.33	83.50	61.00	58.83	59.50	57.50	58.00
	2E-07	83.83	84.33	83.83	83.83	84.00	60.50	57.50	58.33	56.83	56.83
	2E-08	83.33	84.33	84.17	83.67	84.17	60.33	57.67	58.50	57.33	57.00
	2E-09	82.33	84.83	82.83	84.00	83.33	58.67	57.67	57.83	55.83	56.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 128 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	72.00	72.17	72.17	70.92	71.00	83.50	83.25	83.75	83.50	83.50
	2E-04	71.83	71.92	72.00	71.25	71.25	83.75	83.75	83.75	83.75	83.75
	2E-05	72.25	71.92	72.00	71.08	71.25	84.00	83.75	84.00	83.75	83.75
	2E-06	71.67	71.67	71.33	70.42	70.50	83.75	83.75	84.00	83.75	83.75
	2E-07	71.33	71.00	71.00	69.17	69.42	84.25	83.50	83.75	82.75	82.25
	2E-08	71.42	71.00	70.92	69.25	69.25	84.25	83.50	83.50	82.50	82.00
	2E-09	69.75	69.75	69.50	69.33	68.67	83.50	83.00	83.75	82.75	82.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	86.33	85.83	86.17	85.33	85.67	62.17	60.50	61.00	58.67	58.83
	2E-04	86.17	86.17	86.17	85.67	85.33	62.00	60.50	60.33	59.67	59.33
	2E-05	86.33	86.17	86.17	85.67	85.67	61.67	61.00	61.33	59.00	59.33
	2E-06	86.00	86.17	86.67	85.67	85.67	61.83	60.83	61.00	58.50	59.00
	2E-07	85.50	86.00	85.67	85.67	85.83	61.67	59.17	59.67	57.50	57.83
	2E-08	85.33	86.00	85.67	85.50	86.00	61.50	59.17	59.50	58.00	58.00
	2E-09	84.50	86.00	85.33	85.50	84.67	58.00	58.67	58.67	57.33	57.33

Fonte: Jonas Mendonça Targino. 2019

Tabela 129 – Taxa de reconhecimento da técnica SSIMGL com classificador SVM com nível de decomposição LL3

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	92.42	91.42	91.33	90.92	90.58	94.25	94.75	94.50	94.75	94.50
	2E-04	92.08	92.33	91.75	91.83	92.08	95.00	95.00	95.00	95.00	95.00
	2E-05	91.67	92.08	91.67	91.25	91.58	95.00	95.00	95.00	95.25	95.00
	2E-06	91.83	92.08	90.67	90.50	90.92	95.00	95.00	95.00	94.75	95.25
	2E-07	90.42	89.83	89.08	88.25	88.08	93.25	93.25	93.50	92.75	93.00
	2E-08	90.58	89.83	89.08	88.00	88.17	93.25	93.25	93.50	93.00	93.25
	2E-09	87.00	88.33	86.75	87.25	87.42	93.25	93.75	93.25	92.75	92.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	96.50	96.33	96.50	96.00	96.00	92.83	91.17	91.33	90.00	89.67
	2E-04	96.50	96.67	96.50	96.33	96.50	93.33	92.67	93.17	91.67	91.83
	2E-05	96.33	96.17	96.50	96.33	96.00	93.50	92.50	92.83	91.50	91.33
	2E-06	96.17	96.50	96.33	96.17	95.83	92.50	92.33	91.83	90.00	90.00
	2E-07	95.50	96.00	95.67	95.00	94.67	90.83	89.67	90.50	87.33	87.00
	2E-08	95.50	95.83	95.67	94.83	94.83	90.67	89.67	90.67	87.17	87.00
	2E-09	93.83	95.50	94.00	94.67	94.67	86.67	87.50	86.17	85.17	86.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 130 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	70.42	70.75	70.67	69.83	69.75	83.00	82.50	82.50	82.50	82.50
	2E-04	72.00	71.75	71.83	70.83	71.33	83.00	82.75	82.75	83.00	83.00
	2E-05	71.58	70.92	71.58	70.67	70.92	83.00	82.75	82.75	83.00	83.00
	2E-06	71.83	71.42	71.83	70.83	70.83	83.00	82.75	82.75	83.00	83.00
	2E-07	71.00	70.83	71.08	69.92	70.08	83.25	82.75	83.00	82.75	82.50
	2E-08	70.67	70.75	71.00	69.83	70.08	83.25	82.75	83.00	83.00	82.75
	2E-09	70.50	70.58	70.83	69.75	69.92	83.00	82.75	83.00	82.75	83.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	84.67	84.33	84.83	84.00	84.00	60.83	60.00	61.17	57.83	58.17
	2E-04	84.00	84.17	84.00	83.83	83.83	62.17	61.50	62.83	60.83	60.83
	2E-05	83.83	83.83	84.00	83.83	83.83	61.67	61.00	61.67	59.83	60.00
	2E-06	84.00	84.00	84.17	83.83	83.83	61.67	61.17	62.17	59.50	60.33
	2E-07	84.33	84.00	84.33	83.83	84.17	61.33	60.33	61.00	60.00	59.67
	2E-08	84.33	83.67	84.33	83.50	83.83	61.67	60.33	61.17	60.00	59.83
	2E-09	84.17	83.50	84.00	83.67	84.00	61.17	60.33	62.33	60.00	60.50

Fonte: Jonas Mendonça Targino. 2019

Tabela 131 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	71.83	71.92	72.08	71.08	71.17	83.75	83.50	83.50	83.50	83.50
	2E-04	73.17	73.00	73.33	72.42	72.50	83.75	83.75	83.75	83.75	83.75
	2E-05	72.83	72.42	72.83	72.25	72.42	83.75	83.75	83.75	83.75	83.75
	2E-06	73.25	73.00	73.58	72.25	72.50	83.75	83.75	83.75	83.75	84.00
	2E-07	72.08	72.17	72.17	71.50	71.33	84.50	84.00	84.00	84.00	83.75
	2E-08	71.83	72.00	72.08	71.25	71.08	84.50	84.00	84.00	84.00	83.75
	2E-09	71.92	71.92	72.25	71.25	71.25	84.25	84.00	84.25	83.75	84.00

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	86.50	86.83	86.83	86.17	86.50	61.17	60.17	61.83	58.67	58.67
	2E-04	86.00	86.33	86.00	86.00	86.17	62.83	62.83	63.17	61.67	61.50
	2E-05	86.00	86.17	86.00	86.17	86.33	61.67	61.83	62.00	61.33	61.50
	2E-06	86.00	86.00	86.00	86.17	86.33	62.67	62.17	62.67	61.17	61.67
	2E-07	86.17	86.00	86.00	85.83	86.00	62.17	61.33	62.50	60.83	60.50
	2E-08	86.17	86.00	86.00	85.67	85.83	62.00	61.17	62.33	60.83	60.17
	2E-09	86.17	85.83	86.17	86.00	85.83	62.17	61.33	62.17	60.50	60.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 132 – Taxa de reconhecimento da técnica SSIMGL com classificador SVM com nível de decomposição LL2

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	90.67	90.92	90.83	90.17	89.58	94.25	94.50	94.25	94.50	94.25
	2E-04	93.75	94.00	93.92	93.58	93.58	95.25	95.25	95.25	95.00	95.00
	2E-05	93.67	94.33	94.25	93.83	93.92	95.25	95.25	95.25	95.00	95.00
	2E-06	93.67	94.08	94.08	93.92	93.83	95.25	95.25	95.25	95.00	95.00
	2E-07	92.50	92.42	92.83	92.08	91.83	94.50	94.50	94.50	94.25	94.00
	2E-08	92.08	92.00	92.58	91.75	91.33	94.50	94.25	94.50	93.75	93.75
	2E-09	92.00	92.00	91.83	92.00	91.67	94.00	94.50	94.75	94.00	93.75

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	96.50	96.33	96.50	96.33	96.33	91.50	90.67	90.67	90.83	90.17
	2E-04	96.50	96.17	96.33	96.33	96.50	94.17	94.50	94.33	94.17	93.83
	2E-05	96.50	96.33	96.33	96.33	96.33	93.83	94.50	94.50	94.33	94.33
	2E-06	96.50	96.33	96.33	96.33	96.33	94.33	94.67	94.67	94.33	94.50
	2E-07	95.83	95.83	96.00	95.83	95.83	92.33	92.33	91.83	92.67	92.17
	2E-08	95.83	95.83	95.83	95.67	95.50	92.00	92.00	92.17	92.33	91.67
	2E-09	96.00	95.83	95.50	95.67	95.67	92.67	92.67	92.33	92.33	91.67

Fonte: Jonas Mendonça Targino. 2019

Tabela 133 – Taxa de reconhecimento da técnica SRC com grafo de Poisson com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	67.17	66.75	67.00	66.92	66.83	81.00	81.25	81.25	81.25	81.25
	2E-04	71.92	71.83	72.00	71.25	71.25	82.75	82.75	82.75	82.75	82.75
	2E-05	72.08	72.33	72.08	71.67	71.33	83.00	83.00	83.00	83.00	83.00
	2E-06	72.08	72.25	72.25	71.67	71.33	83.00	83.00	83.00	83.00	83.00
	2E-07	72.25	72.50	72.33	71.67	71.67	82.75	82.75	82.75	82.75	82.75
	2E-08	71.67	71.25	71.50	70.67	70.67	84.00	83.50	83.75	83.50	83.50
	2E-09	71.50	71.17	71.33	70.58	70.67	84.00	83.50	83.75	83.50	83.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	84.50	84.50	84.50	84.50	84.50	55.50	55.17	55.33	54.50	54.67
	2E-04	84.50	84.33	84.50	84.17	84.17	62.67	62.83	62.83	62.17	62.00
	2E-05	84.00	84.17	84.00	84.00	84.00	62.83	62.67	62.83	61.83	62.00
	2E-06	84.00	84.00	84.00	84.00	83.83	62.50	62.33	62.67	61.17	60.83
	2E-07	84.17	84.17	84.17	84.17	84.17	63.67	63.00	63.17	61.83	61.83
	2E-08	84.50	84.33	84.33	84.33	84.33	63.83	63.33	63.17	62.67	62.33
	2E-09	84.33	84.33	84.33	84.00	84.33	63.83	63.50	63.67	62.33	62.00

Fonte: Jonas Mendonça Targino. 2019

Tabela 134 – Taxa de reconhecimento da técnica SRC com grafo Laplaciano com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	68.50	68.33	68.42	68.58	68.58	82.00	82.25	82.25	82.00	82.25
	2E-04	73.00	72.83	72.83	72.67	72.50	83.75	83.75	83.75	83.75	83.75
	2E-05	73.08	73.33	73.33	72.83	72.83	83.75	83.75	83.75	83.75	83.75
	2E-06	73.00	73.17	73.17	73.00	72.67	83.75	83.75	83.75	83.75	83.75
	2E-07	73.33	73.67	73.50	73.00	72.83	83.75	83.75	83.75	83.75	83.75
	2E-08	72.83	72.50	73.00	71.92	71.92	84.75	84.50	84.75	84.50	84.50
	2E-09	72.75	72.33	72.75	72.00	71.92	84.75	84.50	84.75	84.50	84.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	86.50	86.50	86.50	86.50	86.50	56.17	56.00	56.17	55.50	55.67
	2E-04	86.50	86.50	86.50	86.17	86.17	63.50	63.33	63.33	62.67	62.67
	2E-05	86.00	86.00	86.00	86.00	86.00	63.17	63.17	63.17	62.50	62.50
	2E-06	86.00	86.00	86.00	86.00	86.00	62.50	63.17	63.17	62.00	61.83
	2E-07	86.50	86.50	86.50	86.50	86.50	63.67	63.50	63.33	62.67	62.50
	2E-08	86.17	86.17	86.17	86.17	86.33	63.67	63.33	63.50	63.33	63.33
	2E-09	86.17	86.17	86.33	86.17	86.33	63.67	63.50	63.83	63.17	63.17

Fonte: Jonas Mendonça Targino. 2019

Tabela 135 – Taxa de reconhecimento da técnica SSIMGL com classificador SVM com nível de decomposição LL1

		AR#1					AR#2				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	82.58	82.83	82.92	82.92	82.92	91.75	91.50	91.75	91.75	91.25
	2E-04	92.92	93.00	92.92	92.83	92.92	95.00	95.00	95.00	95.00	94.75
	2E-05	93.67	93.92	93.75	93.83	93.83	95.25	95.25	95.25	95.25	95.25
	2E-06	93.75	93.83	93.92	93.67	93.58	95.25	95.25	95.25	95.25	95.00
	2E-07	93.75	93.92	93.92	93.42	93.50	95.25	95.50	95.50	95.75	95.50
	2E-08	92.83	92.75	92.58	92.58	92.75	94.50	94.50	94.50	94.50	94.50
	2E-09	92.42	92.33	92.58	92.58	92.67	94.50	94.50	94.50	94.50	94.50

		AR#3					AR#4				
		db2	db4	sym3	sym4	sym5	db2	db4	sym3	sym4	sym5
	Gamma										
	2E-03	96.00	95.83	96.00	95.83	95.83	80.17	81.00	80.67	80.33	80.50
	2E-04	96.33	96.67	96.67	96.50	96.67	93.83	93.83	94.17	93.67	93.50
	2E-05	96.33	96.33	96.33	96.33	96.33	94.17	94.50	94.33	94.17	94.17
	2E-06	96.50	96.33	96.33	96.50	96.33	94.17	94.17	94.33	94.17	94.33
	2E-07	96.33	96.50	96.50	96.50	96.33	93.67	93.50	93.50	93.50	93.50
	2E-08	96.00	96.00	96.00	96.00	96.00	92.50	92.33	92.33	92.00	92.17
	2E-09	95.83	96.00	96.00	96.00	96.00	92.50	92.50	92.17	92.33	92.17

Fonte: Jonas Mendonça Targino. 2019